

# Untersuchung eines hybriden Brain-Computer Interfaces (BCIs) zur optimalen Auslegung als Mensch-Maschine-Schnittstelle

Vom Fachbereich für Physik und Elektrotechnik  
der Universität Bremen

zur Erlangung des akademischen Grades

## Doktor-Ingenieur (Dr.-Ing.)

genehmigte Dissertation

von

M.Sc. Björn Mindermann

wohnhaft in Oyten

Referent: Prof. Dr.-Ing. Axel Gräser

Korreferentin: Prof. Dr. Canan Basar-Eroglu

Eingereicht am: 27. Dezember 2017

Tag des Promotionskolloquiums: 9. April 2018





# Kurzfassung

Menschen mit teilweiser oder vollständiger Lähmung sind meist zur Bewältigung ihres Alltags auf Pflegepersonal angewiesen. Eine Alternative bietet ein Assistenzrobotiksystem, das als Ersatz für die verlorenen motorischen Fähigkeiten fungiert und eine Verbesserung der Lebensqualität ermöglicht. Über eine Mensch-Maschine-Schnittstelle kann der Nutzer das System bedienen und zur Ausführung von autonomen Prozessen veranlassen. Verfügt das System über einen Roboterarm, so ist die behinderte Person in der Lage, Objekte zu greifen und zu bewegen. Im Falle eines Fehlers, seitens des Systems, muss der Anwender in der Lage sein, den Roboterarm direkt zu steuern.

Mit der in dieser Arbeit entwickelten Schnittstelle kann ein Mensch den Greifer eines Roboterarmes in jede Position und Orientierung bringen sowie ein Öffnen und Schließen des Greifers bewirken. Zur Zielgruppe des Systems gehören Menschen mit sehr begrenzten Bewegungsmöglichkeiten, weshalb zur Kommunikation ein Brain-Computer Interface (BCI) zum Einsatz kommt. Dieses etabliert einen Kommunikationskanal zwischen dem menschlichen Gehirn und dem zu steuernden Roboter. Zur Aufnahme der Gehirnströme wird ein spezieller Helm verwendet, der neben den Messelektroden über einen Stimulator im peripheren Sichtfeld des Nutzers verfügt. Dieser Stimulator besitzt vier Stimuli und sorgt über diese für eine Evokation von ereigniskorrelierten und visuellen Potenzialen. Durch die Detektion von Steady-State Visual Evoked Potentials (SSVEPs) und P300-Potenzialen kann das System feststellen, auf welchen Stimulus der Nutzer seine Konzentration gerichtet hat. Hiermit verfügt der Nutzer über vier diskrete Kommandos zur Steuerung des Roboters. Zum Ein- und Ausschalten des Stimulators dienen Bewegungsvorstellungen. Zur Steuerung des Roboters wird ein Zustandsautomat verwendet,

---

der für jede Translations- und Rotationsbewegung eine Steuerungsgruppe besitzt. Implementiert wurde eine schrittweise Steuerung, in der der Greifer diskrete Schritte ausführt, und eine geschwindigkeitsbasierte Steuerung, in der die Bewegung des Greifers gestartet und gestoppt wird. Der Sprung in eine Steuerungsgruppe erfolgt über das sequentielle Senden von zwei Kommandos. In einer Gruppe kann der Nutzer eine Bewegung in positiver und negativer Richtung der ausgewählten Achse ausführen, die Schrittweite oder die Geschwindigkeit verändern und die Gruppe verlassen. Ein Stoppen an der Zielposition und in Gefahrensituationen erfolgt über ein Schließen und Geschlossenhalten der Augen und die dabei auftretenden Artefakte und Alphawellen in den Signalen. Beide Steuerungen wurden im Rahmen einer Studie getestet und unter objektiven und subjektiven Kriterien evaluiert. Die Versuche haben gezeigt, dass eine BCI-basierte Roboterarmsteuerung durchführbar und nützlich ist.

# Abstract

People with partial or complete paralysis are usually dependent on nursing staff to cope with their daily activities. Alternatively, an assistance robotics system serves as a substitute for the lost motor skills and enables an improvement in the quality of life. With the help of a human-machine interface, the user can operate the system and initiate autonomous processes. If the system consists of a robot arm, the disabled person is able to grab and move objects. In the case of an error caused by the system, the user should be able to control the robot arm directly.

With the interface developed in this work, a human being can open or close as well as move the robot gripper into any position and orientation. Since the target group of the system is people with very limited body movements, a Brain-Computer Interface (BCI) is used for communication. It establishes a communication channel between the human brain and the controlled robot arm. A special helmet is used for recording the brain signals, which, in addition to the measuring electrodes, has a stimulator in the peripheral field of vision of the user. This stimulator has four stimuli by which an evocation of event-related and visual potentials are provided. By detecting Steady-State Visual Evoked Potentials (SSVEPs) and P300 potentials, the system can determine which stimulus the user has focused on. With this, four discrete commands are provided for the user to control the robot. For switching the stimulator on and off motor imaginations are used. A state machine with a control group for each translational and rotational movement is used to control the robot. A stepwise control, in which the gripper performs discrete steps, and a speed-based control, in which the movement of the gripper is started and stopped has been implemented. Switching between groups is performed by the sequential

---

sending of two commands. In each group, the user can perform a movement in the positive and negative direction of the selected axis, change the step width or speed, and leave the group. Stopping at the target position and in dangerous situations occurs by closing the eyes and the thereby occurring artifacts and alpha waves in the signals. Both control concepts were tested in a study and evaluated with objective and subjective criteria. The experiments have shown that BCI-based robot arm control is feasible and useful.

# Inhaltsverzeichnis

<b>Kurzfassung</b>	<b>iii</b>
<b>Abstract</b>	<b>v</b>
<b>Abbildungsverzeichnis</b>	<b>xiii</b>
<b>Tabellenverzeichnis</b>	<b>xix</b>
<b>Abkürzungsverzeichnis</b>	<b>xxiii</b>
<b>1. Einleitung</b>	<b>1</b>
1.1. Stand der Forschung . . . . .	3
1.2. Hauptbeiträge der Arbeit . . . . .	7
1.3. Gliederung der Arbeit . . . . .	10
<b>2. Brain-Computer Interfaces (BCIs)</b>	<b>13</b>
2.1. Definition eines BCIs . . . . .	13
2.2. Messung der Gehirnaktivität . . . . .	15
2.2.1. Elektroenzephalographie (EEG) . . . . .	16
2.3. Signalverarbeitung . . . . .	20
2.3.1. Vorverarbeitung . . . . .	20
2.3.2. Merkmalsextraktion . . . . .	21
2.3.3. Klassifikation . . . . .	23
2.4. Anwendungsprogramme . . . . .	24
2.4.1. Kommunikation . . . . .	25

2.4.2.	Umgebungssteuerung . . . . .	26
2.4.3.	Fortbewegung . . . . .	27
2.4.4.	Wiederherstellung der motorischen Funktion . . . . .	28
2.4.5.	Anwendungen für gesunde Nutzer . . . . .	28
2.5.	Bewertung von BCIs . . . . .	29
2.5.1.	Kreuzvalidierung . . . . .	29
2.5.2.	Konfusionsmatrix . . . . .	30
2.5.3.	Statistische Gütekriterien der Klassifikation . . . . .	30
2.5.4.	Receiver Operating Characteristics (ROC)-Graphen . . . . .	32
2.5.5.	Informationstransferrate (ITR) . . . . .	34
2.6.	Neurophysiologische Signale für EEG-basierte BCIs . . . . .	34
2.6.1.	Steady-State Visual Evoked Potentials (SSVEPs) . . . . .	35
2.6.2.	P300-Potenziale . . . . .	38
2.6.3.	Fehlerpotenziale . . . . .	40
2.6.4.	Sensomotorische Rhythmen (SMR) . . . . .	43
2.6.5.	Alphawellen und Augenartefakte . . . . .	47
<b>3.</b>	<b>Swift Brain-Computer Interface (sBCI)-System</b>	<b>51</b>
3.1.	Hardware . . . . .	52
3.2.	Software . . . . .	55
3.2.1.	SSVEP-BCI . . . . .	56
3.2.2.	ERD/ERS-BCI . . . . .	62
3.2.3.	Nutzerschnittstelle und Steuermethoden . . . . .	71
3.3.	Test des sBCI-Systems . . . . .	74
3.3.1.	Teilnehmer der Studie . . . . .	74
3.3.2.	Datenaufnahme . . . . .	75
3.3.3.	Training von Probanden für Bewegungsvorstellungen . . . . .	75
3.3.4.	Steuerung von Haushaltsgeräten . . . . .	80

3.3.5. Diskussion der Ergebnisse . . . . .	85
<b>4. Schrittweise Steuerung eines Roboterarmes über ein hybrides BCI</b>	<b>89</b>
4.1. Systemanforderungen und -übersicht . . . . .	90
4.2. SSVEPs als Umschalt- und Steuermodalität . . . . .	93
4.2.1. Stimulus . . . . .	94
4.2.2. Signalverarbeitung . . . . .	95
4.2.3. Kalibrierung . . . . .	100
4.3. P300-Potenziale als Umschalt- und Steuermodalität . . . . .	109
4.3.1. Stimulus . . . . .	109
4.3.2. Signalverarbeitung . . . . .	111
4.3.3. Kalibrierung . . . . .	114
4.4. Zustandsautomaten für eine Roboterarmsteuerung . . . . .	118
4.4.1. 1-Tupel Zustandsautomat . . . . .	120
4.4.2. 2-Tupel Zustandsautomat . . . . .	122
4.5. Implementierung der Roboterarmregelung . . . . .	124
4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustands- automaten . . . . .	127
4.6.1. Versuchsteilnehmer . . . . .	128
4.6.2. Datenaufnahme . . . . .	129
4.6.3. Versuchsprotokoll . . . . .	130
4.6.4. Evaluierung der Umschalt- und Steuermodalitäten . . . . .	132
4.6.5. Evaluierung der Zustandsautomaten . . . . .	137
4.7. Test der schrittweisen Roboterarmsteuerung . . . . .	140
4.7.1. Versuchsteilnehmer . . . . .	140
4.7.2. Datenaufnahme . . . . .	141
4.7.3. Versuchsprotokoll . . . . .	141
4.7.4. Evaluierung . . . . .	143

<b>5. Geschwindigkeitsbasierte Steuerung eines Roboterarmes über ein hybrides BCI</b>	<b>151</b>
5.1. Systemanforderungen und -übersicht . . . . .	152
5.2. Alphawellen als Stoppmodalität . . . . .	154
5.2.1. Signalverarbeitung . . . . .	155
5.2.2. Kalibrierung . . . . .	164
5.3. Augenartefakte als Stoppmodalität . . . . .	169
5.3.1. Signalverarbeitung . . . . .	170
5.3.2. Kalibrierung . . . . .	173
5.4. Vergleich der Stoppmodalitäten . . . . .	178
5.4.1. Versuchsteilnehmer . . . . .	180
5.4.2. Datenaufnahme . . . . .	181
5.4.3. Versuchsprotokoll . . . . .	181
5.4.4. Evaluierung . . . . .	183
5.5. Test der geschwindigkeitsbasierten Roboterarmsteuerung . . . . .	192
5.5.1. Versuchsteilnehmer . . . . .	192
5.5.2. Datenaufnahme . . . . .	193
5.5.3. Versuchsprotokoll . . . . .	193
5.5.4. Evaluierung . . . . .	194
<b>6. Verfahren zur Detektion und Korrektur von Fehlern</b>	<b>205</b>
6.1. Fehler bei der Navigation im Zustandsautomaten . . . . .	205
6.1.1. Signalverarbeitung . . . . .	206
6.1.2. Kalibrierung . . . . .	207
6.2. Fehler durch Zielabweichungen bei einer aktiven und passiven Steuerung	217
6.2.1. Signalverarbeitung . . . . .	218
6.2.2. Kalibrierung . . . . .	219



<b>7. Zusammenfassung und Ausblick</b>	<b>229</b>
7.1. Zusammenfassung . . . . .	229
7.2. Ausblick . . . . .	233
<b>Literaturverzeichnis</b>	<b>237</b>
<b>A. Testdaten der sBCI-Studie</b>	<b>265</b>
<b>B. Testdaten der schrittweisen Roboterarmsteuerung</b>	<b>269</b>
<b>C. Testdaten der geschwindigkeitsbasierten Roboterarmsteuerung</b>	<b>273</b>
<b>D. Testdaten der Fehlererkennung</b>	<b>275</b>



# Abbildungsverzeichnis

1.1. Systemübersicht der BCI-basierten Roboterarmsteuerung. . . . .	8
2.1. Die Komponenten eines BCIs. . . . .	14
2.2. Das internationale 10-20-System. . . . .	18
2.3. Graphische Benutzeroberflächen BCI-basierter Kommunikationsanwen- dungen. . . . .	25
2.4. Ein ROC-Graph mit vier diskreten Klassifikatoren und eine ROC-Kurve mit den Schwellwerten für jeden Punkt. . . . .	33
2.5. Amplitude und Phase eines SSVEP-BCIs. . . . .	37
2.6. P300-Komponente eines ereigniskorrelierten Potenzials und eine mögliche Matrixanordnung zum Evozieren des Potenzials. . . . .	38
2.7. Zeitliche und topografische Darstellung eines Fehlerpotenzials. . . . .	42
2.8. Amplitudenspektrum, Signalleistung und ERD/ERS-Verläufe während der Bewegungsvorstellung der linken Hand. . . . .	44
2.9. Topografische Darstellung der Differenz (gemessen als $r^2$ ) zwischen der Ruhephase und einer Bewegungsvorstellung. . . . .	46
2.10. Zeit-Frequenz-Diagramm für das Schließen der Augen. . . . .	48
2.11. Signalverläufe verschiedener Augenartefakte. . . . .	49
3.1. Komponenten des sBCI-Helms. . . . .	52
3.2. Elektrodenanordnung und -halterung des sBCI-Helms. . . . .	53
3.3. Hybrides ERD/ERS- und SSVEP-BCI mit sequentieller Verarbeitung. . .	72

3.4. Die sBCI-Benutzeroberfläche zur Steuerung eines Internet-Radios, eines Kühlschranks und einer Mikrowelle. . . . .	73
3.5. Zuordnung der Bewegungsvorstellungen und der LEDs zu den Steuerkommandos. . . . .	74
3.6. Zeitlicher Ablauf der Kalibrierung von Bewegungsvorstellungen. . . . .	77
3.7. Zeitlicher Ablauf des Trainings von Bewegungsvorstellungen. . . . .	78
3.8. Die maximalen Genauigkeiten der Probanden beim Training von Bewegungsvorstellungen an drei Sitzungen. . . . .	80
3.9. Verteilungen der von den Probanden erreichten Genauigkeiten beim Training von Bewegungsvorstellungen. . . . .	81
3.10. Die pro Kommando benötigten Zeiten der Probanden bei der Auswahl von Haushaltsgeräten mit dem ERD/ERS-BCI. . . . .	83
3.11. Verteilungen der Zeiten pro Kommando beim ERD/ERS-BCI und der Genauigkeiten und der ITR beim SSVEP-BCI. . . . .	84
3.12. Genauigkeiten und Informationstransferraten der Probanden bei der Steuerung von Haushaltsgeräten mit dem SSVEP-BCI. . . . .	84
4.1. Darstellung der BCI-basierten Roboterarmsteuerung. . . . .	92
4.2. Zuordnung der Frequenzen und Phasen zu den vier LEDs des sBCI-Helmes bei einem frequenz- und phasenbasiertem SSVEP-BCI sowie die Darstellung der verwendeten Blinksequenzen. . . . .	95
4.3. Zeitlicher Ablauf der SSVEP-Kalibrierung. . . . .	102
4.4. Darstellung der berechneten Wahrscheinlichkeiten und Phasen für eine Stimulationsfrequenz von 24 Hz in Polarkoordinaten. . . . .	105
4.5. Darstellung der berechneten Merkmale und Klassenregionen für eine Stimulationsfrequenz von 24 Hz in kartesischen Koordinaten. . . . .	106
4.6. Verteilungen der Klassifikationsgenauigkeiten für verschiedene Parameter bei der Verwendung eines phasenbasierten SSVEP-BCIs. . . . .	107

4.7. Verteilungen der Genauigkeiten für Stimulationsfrequenzen von 10 bis 39 Hz bei der Verwendung eines phasenbasierten SSVEP-BCIs. . . . .	108
4.8. Zuordnung der Zeichen aus der P300-Matrix zu den vier LEDs des sBCI-Helmes. . . . .	110
4.9. Zeitlicher Ablauf der P300-Kalibrierung. . . . .	116
4.10. Veränderung der Klassifikationsgenauigkeit mit steigender Anzahl an Intensivierungen pro Stimulus bei der Verwendung eines P300-BCIs. . . . .	117
4.11. Zuordnung der LEDs zu den Umschalt- und Steuerkommandos. . . . .	119
4.12. 1-Tupel Zustandsautomat für die schrittweise Steuerung eines Roboterarmes. . . . .	121
4.13. Darstellung der in ROS implementierten Roboterarmregelung. . . . .	125
4.14. Gemittelte ITR und Genauigkeit von jedem Probanden, der das frequenzbasierte SSVEP-BCI und die LEDs des sBCI-Helmes nutzte. . . . .	133
4.15. Gemittelte ITR und Genauigkeit von jedem Probanden, der das P300-BCI und die LEDs des sBCI-Helmes nutzte. . . . .	134
4.16. Gemittelte ITR und Genauigkeit von jedem Probanden, der das frequenzbasierte SSVEP-BCI und die großen LEDs nutzte. . . . .	135
4.17. Gemittelte ITR und Genauigkeit von jedem Probanden, der das phasenbasierte SSVEP-BCI und die großen LEDs nutzte. . . . .	135
4.18. Verteilungen der Genauigkeiten und der ITR unter Nutzung der verschiedenen Paradigmen. . . . .	136
4.19. Verteilungen der Genauigkeiten, der ITR und der benötigten Zeiten zur Absolvierung der vier Aufgaben unter Nutzung des 1- und 2-Tupel Zustandsautomaten. . . . .	138
4.20. Experimenteller Aufbau für den Test der BCI-basierten Roboterarmsteuerung. . . . .	142
4.21. Die Trajektorien zur Bearbeitung der Pick-and-Place-Aufgabe. . . . .	143

4.22. Die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der ersten und zweiten Teilaufgabe. . . . .	144
4.23. Verteilungen der benötigten Zeiten für die erste und die zweite Teilaufgabe und der benötigten Umschalt- und Steuerkommandos. . . . .	145
4.24. Verteilungen der gesamten Bearbeitungszeiten und der benötigten Steuer- erkommandos für den ersten und den zweiten Versuch. . . . .	147
4.25. Verteilungen der subjektiven Bewertungen anhand des NASA-TLX-Fra- gebogens. . . . .	148
4.26. Verteilungen der subjektiven Bewertungen anhand des selbst entwickelten Fragebogens. . . . .	150
5.1. Vergleich von zwei Metriken zur Klassifikation von geschlossenen Augen und geöffneten Augen anhand von Alphawellen. . . . .	158
5.2. Zeitlicher Ablauf der Alphawellen-Kalibrierung. . . . .	166
5.3. Zeit-Frequenz-Diagramme beim Schließen der Augen. . . . .	168
5.4. Ergebnisse für die Klassifikation von geschlossenen Augen anhand von Alphawellen. . . . .	169
5.5. Zeitlicher Ablauf der Augenartefakt-Kalibrierung. . . . .	175
5.6. Zeitliche und topografische Darstellung von Augenartefakten. . . . .	177
5.7. Ergebnisse für die Klassifikation von einem Schließen der Augen anhand von Augenartefakten. . . . .	178
5.8. Zeitlicher Ablauf für den Test einer Stoppmodalität. . . . .	179
5.9. Detektionszeiten der Modalitäten zum Stoppen des Roboterarmes. . . . .	184
5.10. Zuverlässigkeit des Alphawellen-BCIs zum Stoppen des Roboterarmes. . . . .	185
5.11. Zuverlässigkeit des Augenartefakt-HMIs zum Stoppen des Roboterarmes. . . . .	186
5.12. Zuverlässigkeit des SSVEP-BCIs zum Stoppen des Roboterarmes. . . . .	187
5.13. Zuverlässigkeit des ERP-BCIs zum Stoppen des Roboterarmes. . . . .	188
5.14. Genauigkeiten der Modalitäten zum Stoppen des Roboterarmes. . . . .	190

5.15. Die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der ersten und zweiten Teilaufgabe. . . . .	195
5.16. Verteilungen der benötigten Zeiten für die erste und die zweite Teilaufgabe und der benötigten Umschalt- und Steuerkommandos. . . . .	196
5.17. Verteilungen der gesamten Bearbeitungszeiten und der benötigten Steuer- erkommandos für den ersten und den zweiten Versuch. . . . .	198
5.18. Verteilungen der benötigten Zeiten und der Umschalt- und Steuerkom- mandos unter Verwendung der schrittweisen und der geschwindigkeitsba- sierten Roboterarmsteuerung. . . . .	200
5.19. Verteilungen der subjektiven Bewertungen anhand des NASA-TLX-Fra- gebogens. . . . .	201
5.20. Verteilungen der subjektiven Bewertungen anhand des selbst entwickelten Fragebogens. . . . .	202
6.1. Zeitlicher Ablauf zur Aufnahme von Fehlerpotenzialen. . . . .	209
6.2. Zeitliche und topografische Darstellung von Fehlerpotenzialen. . . . .	211
6.3. Ergebnisse für die Klassifikation von Fehlerpotenzialen. . . . .	212
6.4. Wahrscheinlichkeitsbaum für ein BCI mit Fehlererkennung. . . . .	213
6.5. Veränderung der Genauigkeit und der ITR (gemessen in Bits pro Wieder- holung) eines BCIs mit Fehlererkennung. . . . .	215
6.6. Veränderung der ITR eines BCIs mit Fehlererkennung gemessen in Bits pro Minute. . . . .	217
6.7. Zeitliche und topografische Darstellung von ereigniskorrelierten Potenzia- len bei einer passiven Steuerung. . . . .	223
6.8. Zeitliche und topografische Darstellung von ereigniskorrelierten Potenzia- len bei einer aktiven Steuerung. . . . .	224
6.9. Vergleich der Klassifikationsergebnisse bei einer passiven und aktiven Steuerung anhand von ereigniskorrelierten Potenzialen. . . . .	226





# Tabellenverzeichnis

2.1. Konfusionsmatrix für einen binären Klassifikator. . . . .	30
3.1. Aufgaben zur Steuerung von Haushaltsgeräten mit dem sBCI-System. . .	82
4.1. Zuordnung der 2-Tupel Kommandos zu den Steuerungsgruppen. . . . .	123
4.2. Probandeninformationen der Studie zum Vergleich der Umschalt- und Steuermodalitäten und der Zustandsautomaten. . . . .	129
4.3. Aufgaben für die Bedienung des Zustandsautomaten. . . . .	131
5.1. Informationen über die Probanden, die an der Studie zum Vergleich der Stoppmodalitäten teilnahmen. . . . .	180
6.1. Informationen über die Probanden, die an der Kalibrierung der aktiven und passiven Steuerung teilnahmen. . . . .	220
A.1. Ergebnisse der Studie aus Abschnitt 3.3 für die Auswahl von Haushalts- geräten mit dem ERD/ERS-BCI. . . . .	265
A.2. Ergebnisse der Studie aus Abschnitt 3.3 für die Steuerung von Haushalts- geräten mit dem SSVEP-BCI. . . . .	266
A.3. Ergebnisse der Studie aus Abschnitt 3.3.3 für das Training von Bewe- gungsvorstellungen. . . . .	267
B.1. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zu- standsautomaten mit dem frequenzbasierten SSVEP-BCI und den großen LEDs. . . . .	269

B.2. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem phasenbasierten SSVEP-BCI und den großen LEDs. . . . .	270
B.3. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem P300-BCI und den LEDs des sBCI-Helmes. . . . .	270
B.4. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes. . . . .	271
B.5. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 2-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes. . . . .	271
B.6. Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel und des 2-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes. . . . .	272
B.7. Ergebnisse der Studie aus Abschnitt 4.7 für die schrittweise Roboterarmsteuerung. . . . .	272
C.1. Kalibrierungsergebnisse für das Alphawellen-BCI. . . . .	273
C.2. Kalibrierungsergebnisse für das Augenartefakt-HMI. . . . .	274
C.3. Ergebnisse der Studie aus Abschnitt 5.5 für die geschwindigkeitsbasierte Roboterarmsteuerung. . . . .	274
D.1. Ergebnisse der Kalibrierung aus Abschnitt 6.1 für das ErrP-BCI. . . . .	275
D.2. Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem MDRM-Klassifikator und einer aktiven Steuerung. . . . .	276
D.3. Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem FGMDRM-Klassifikator und einer aktiven Steuerung. . . . .	276
D.4. Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem MDRM-Klassifikator und einer passiven Steuerung. . . . .	277

D.5. Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem FGMDRM-Klassifikator und einer passiven Steuerung. . . . .	277
--	-----



# Abkürzungsverzeichnis

AAR	adaptiv autoregressiv
ACC	Accuracy
Ag/AgCl	Silber/Silberchlorid
ALS	amyotrophe Lateralsklerose
AR	autoregressiv
AUC	Area Under the Curve
BA	Balanced Accuracy
BCI	Brain-Computer Interface
BSS	Blind Source Separation
CAR	Common Average Reference
CBP	Checkerboard Paradigm
CLIS	Completely Locked-In State
CSP	Common Spatial Pattern
DOF	Degree of Freedom
ECoG	Elektrokortikographie

EEG	Elektroenzephalographie
EKG	Elektrokardiographie
EMG	Elektromyographie
EOG	Elektrookulographie
EPSP	exzitatorisches postsynaptisches Potenzial
ERD	Event-Related Desynchronization
ERP	Event-Related Potential
ERR	Error Rate
ErrP	Error Potential
ERS	Event-Related Synchronization
FES	Funktionelle Elektrostimulation
FFT	Fast Fourier Transformation
FGMDRM	Filter Geodesic Minimum Distance to Riemannian Mean
FIFO	First In - First Out
FIR	Finite Impulse Response
fMRT	funktionelle Magnetresonanztomographie
FN	False Negative
fNIRS	funktionelle Nahinfrarotspektroskopie
FP	False Positive
FPR	False Positive Rate
FRIEND	Functional Robot arm with user-friENdly interface for Disabled people
HMD	Head-Mounted Display
HMI	Human-Machine Interface

HRI	Human-Robot Interface
IAT	Institut für Automatisierungstechnik
IC	Intentional Control
ICA	Independent Component Analysis
IR	Infrarot
ISI	Interstimulus-Intervall
ITI	Inter-Trial-Intervall
ITR	Informationstransferrate
LDA	lineare Diskriminanzanalyse
LED	Light-Emitting Diode
LIS	Locked-In State
LWA	Lightweight Arm
MA	Moving Average
MCC	Maximum-Contrast-Combination
MD	Mahalanobis Distanz
MDRM	Minimum Distance to Riemannian Mean
MEC	Minimum-Energy-Combination
MEG	Magnetenzephalographie
MI	Motor Imagery
MLP	Multi-Layer Perceptron
MRMR	Maximum Relevanz Minimum Redundanz
MS	multiple Sklerose

MTM	Multitaper-Methode
NASA-TLX	NASA Task Load Index
NC	Non Control
Ne	Error Negativity
NER	Neural Engineering
NN	neuronales Netz
PCA	Principal Component Analysis
Pe	Error Positivity
RBF	Radial Basis Function
RCP	Row/Column Paradigm
ROC	Receiver Operating Characteristics
ROS	Robot Operating System
sBCI	Swift Brain-Computer Interface
SCM	Sample Covariance Matrix
SCP	Single-Character Paradigm
SD	Standard Deviation
SIC	Schwarz Information Criterion
SMD	Surface Mounted Device
SMR	sensomotorischer Rhythmus
SNR	Signal-to-Noise Ratio
SPD	symmetrisch positiv-definit



SQP	Sequential Quadratic Programming
SRDF	Semantic Robot Description Format
SSVEP	Steady-State Visual Evoked Potential
SVM	Support Vector Machine
swLDA	Stepwise Linear Discriminant Analysis
TAS	True Active Shielding
TN	True Negative
TNR	True Negative Rate
TP	True Positive
TPR	True Positive Rate
TVEP	Transient Visual Evoked Potential
UDP	User Datagram Protocol
URDF	Unified Robot Description Format
VEP	Visual Evoked Potential



# Kapitel 1.

## Einleitung

Der größte Teil von technischen Geräten wird unter Zuhilfenahme der Gliedmaßen gesteuert. Kann der Mensch aufgrund einer Verletzung seines Rückenmarks oder des Verlustes seiner Gliedmaßen diese Geräte nicht mehr manuell bedienen, so müssen alternative Steuerungsmöglichkeiten gefunden werden. Um diese Anforderung zu erfüllen, wurden verschiedene Mensch-Maschine-Schnittstellen (engl. Human-Machine Interfaces (HMIs)) entwickelt, die unterschiedliche Arten von Biosignalen verwenden. Es existieren Systeme basierend auf Elektromyographie (EMG) [8], Elektrookulographie (EOG) [77], Elektroenzephalographie (EEG) [108], Sprache [74] sowie Kopf- [153] und Augenbewegungen [6]. Mit diesen Schnittstellen können behinderte Menschen einen Teil ihrer Autonomie zurücklangen, um so ihre Lebensqualität zu verbessern.

Assistenzrobotiksysteme, wie der Roboter FRIEND (Functional Robot arm with user-friendly interface for Disabled people) [63], der aus einem Rollstuhl, einem Kamerasystem, einem Roboterarm und einem Handgreifer besteht, wurden entwickelt, um die Autonomie von behinderten Nutzern in Alltagsszenarien wiederherzustellen. Ein wirtschaftliches Unterstützungssystem muss die Unabhängigkeit des Benutzers vom Pflegepersonal für mehrere Stunden gewährleisten. Der Nutzer benötigt deshalb die vollständige Kontrolle über das HMI, welche wiederum vollständig von den verbliebenen geistigen und physischen Fähigkeiten des Nutzers abhängt. Hinzu kommt noch die Möglichkeit, dass sich die Bewegungsfähigkeiten, je nach Art der Behinderung, allmählich oder plötzlich

verändern können. HMI-Konzepte, die zu einem bestimmten Zeitpunkt noch hilfreich sind, wie z.B. Systeme, die Kopfbewegungen nutzen, können später nicht mehr verwendet werden. Dies gilt beispielsweise für Patienten mit Muskeldystrophie, multiple Sklerose (MS) oder amyotrophe Lateralsklerose (ALS), bei denen bewegungsbasierte Kommunikationsfähigkeiten mit der Zeit nachlassen. Für Nutzer mit sehr begrenzten Bewegungsmöglichkeiten kommen dann Brain-Computer Interfaces (BCIs) zum Einsatz.

Ein BCI ermöglicht die Etablierung eines Kommunikationskanals zwischen dem menschlichen Gehirn und einem zu steuernden Gerät. BCIs detektieren die Intention eines Menschen und übersetzen diese in Kommandos. Hierfür stehen eine Vielzahl an elektrophysiologischen Signalkomponenten zur Verfügung. Zu diesen Komponenten zählen hauptsächlich Steady-State Visual Evoked Potentials (SSVEPs) [183, 2], P300-Potenziale [162] und sensomotorische Rhythmen (SMR) [136, 126]. Aufgenommen werden diese Komponenten entweder von der Kopfhaut mittels EEG oder direkt vom Kortex durch die Verwendung von Elektrokortikographie (ECoG).

Mit Hilfe eines BCIs kann der Mensch ein Assistenzsystem zur Ausführung von autonomen Operationen veranlassen (z.B. zum Greifen einer Flasche). Die auszuführenden Aktionen sind über Befehle auf einer hohen Abstraktionsebene auswählbar. In einer dynamischen Umgebung kommt es jedoch zu sich verändernden Lichtverhältnissen, die eine Erkennung der zu greifenden Objekte erschweren oder verhindern können. Diese und andere unvorhergesehene Ereignisse können dazu führen, dass das System nicht in der Lage ist, die Aktion selbständig zu Ende zu führen. In diesem Fall muss der Nutzer korrigierend in den Prozess eingreifen. Für einen Greifprozess wird daher eine direkte Roboterarmsteuerung benötigt, die es dem Nutzer ermöglicht, selbständig den Greifer in jede Pose zu bringen sowie ein Öffnen und Schließen des Greifers zu bewirken.

## 1.1. Stand der Forschung

Die Modulation der beiden Frequenzbänder  $\mu$  (7-13 Hz) und  $\beta$  (13-30 Hz), hervorgerufen durch die Vorstellung von Körperbewegungen [136, 126], hat ein großes Interesse als ein natürliches Paradigma für nicht-invasive BCIs gewonnen. SMR-Modulationsmuster, in Form von Event-Related Desynchronization (ERD) und Event-Related Synchronization (ERS), erlauben dem Nutzer jederzeit Steuerungssignale nach freiem Willen zu erzeugen. Ein ERD/ERS-BCI gehört zu den endogenen Systemen und benötigt keine externe Stimulation. Für seine Verwendung ist ein intensives Nutzertraining erforderlich. Außerdem ist die Ausgabe von ERD/ERS-basierten BCIs weniger zuverlässig und die Kommunikationsgeschwindigkeit deutlich geringer im Vergleich zu anderen BCI-Paradigmen [128].

In den Veröffentlichungen [73, 72] wurde ein HMI erstellt, welches in der Lage ist, einen Industrieroboter über Bewegungsvorstellungen zu steuern. Die Experimente hatten zur Aufgabe, vier bekannte Ziele innerhalb einer horizontalen Ebene mit einem Robotergreifer anzufahren. Sofern das System eine von vier möglichen Bewegungsvorstellungen mehrfach hintereinander erkennt, führt der Roboter eine Bewegung von 40 mm/s in die entsprechende Richtung aus. Nach einem kurzen Training waren die Testpersonen in der Lage, den Roboter in einer Realzeitanwendung zu steuern. Diese Art von System eignet sich jedoch lediglich für eine zweidimensionale Steuerung.

Eine Steuerung in drei Dimensionen lässt sich durch die Hinzunahme von weiteren Bewegungsvorstellungen realisieren, wie in der Arbeit [18] gezeigt wird. In dieser Veröffentlichung wird die Klassifikation der Finger-, Ellbogen- und Schulterbewegungsvorstellung der linken und rechten Hand zur Steuerung eines Roboters in einer dreidimensionalen Simulationsumgebung genutzt. Der Nutzer kann mit diesen Bewegungsvorstellungen die beiden Gelenke des Roboters steuern und Objekte greifen oder loslassen. Die Erfolgsrate zur Erreichung der vorgegebenen Ziele betrug 85 %.

Ein Ansatz zur Steuerung im dreidimensionalen Raum mit nur vier Bewegungsvorstellungen wird in der Arbeit [103] vorgestellt. Das Ziel dieser Arbeit bestand in der

Steuerung eines Manipulators durch die Klassifikation von fünf mentalen Zuständen (Bewegungsvorstellung der linken und rechten Hand, der Füße und der Zunge sowie der Ruhezustand). Um eine Bewegungssteuerung des Manipulators im dreidimensionalen kartesischen Raum zu realisieren, werden sechs 2-Tupel Kommandos verwendet. Diese 2-Tupel Kommandos sind Sequenzen von den fünf einzelnen Klassen. Der Arbeitsraum des Roboters wird in einen inneren und äußeren Bereich aufgeteilt, entsprechend der Entfernung zur Basis des Roboters. Der innere Raum wiederum ist in einzelne Punkte unterteilt, die in einer Gitterstruktur angeordnet sind. Solange sich der Greifer des Roboters im inneren Bereich befindet, bewegt sich dieser nach jedem Kommando von Punkt zu Punkt. Tritt der Arm in den äußeren Bereich ein, so findet eine Richtungssteuerung statt. Diese dient dazu, wieder in den inneren Bereich zurückzukehren. Ein Öffnen und Schließen des Greifers sowie die Durchführung von rotatorischen Bewegungen ist mit dem System nicht möglich.

Ebenfalls können Veränderungen der Alpha-Rhythmen ohne externe Stimulation erreicht werden. Alphawellen sind über dem okzipitalen Bereich des Gehirns zu beobachten und liegen in einem Frequenzbereich von 8 bis 12 Hz. Ein Anstieg ihrer Amplituden tritt auf, wenn eine Person wach und entspannt ist oder die Augen geschlossen hält. Sobald die Augen geöffnet werden und eine mentale Anstrengung stattfindet, tritt eine Abschwächung der Amplituden auf [62].

Alphawellen ermöglichen ebenfalls die Steuerung eines Roboterarmes, wie in der Arbeit [78] gezeigt wird. Zur Auswahl eines Kommandos muss der Anwender zuerst die Augen schließen. Über einen akustischen Ton werden der Reihe nach vier Kommandos genannt, die einen Wechsel in einem Zustandsautomaten bewirken. Werden Alphawellen detektiert, so wird das nächste Kommando angekündigt. Zur Auswahl des Kommandos muss der Nutzer seine Augen öffnen und somit die Erzeugung von Alphawellen verringern. Der Roboterarm kann nach oben, unten, rechts und links bewegt sowie gestoppt werden. Außerdem lässt sich der Greifer öffnen und schließen. Während der Ausführung

des Kommandos sind die Augen des Anwenders geöffnet. Die Bewegung wird solange ausgeführt, bis der Nutzer die Augen schließt. In diesem Fall kann der Anwender ein weiteres Kommando erzeugen. In einer Studie erhielten Probanden die Aufgabe, eine Box mit einem Roboterarm zu greifen und an einer Zielposition zu platzieren. Die Genauigkeiten lagen zwischen 70 und 95 %. Zur Auswahl eines Kommandos wird sehr viel Zeit benötigt, da jedes Kommando erst angekündigt werden muss. Auch kommt es mit der Zeit zu einer Abschwächung der Alphawellen und somit zu der Auswahl von falschen Kommandos. Der Nutzer muss seine Aktionen vorausschauend planen, da er zur Auswahl eines Kommandos seine Augen geschlossen halten muss.

Exogene BCIs, auf der Basis von evozierten Potenzialen, wie SSVEP und P300, besitzen den Vorteil, dass für ihre Verwendung kein Training notwendig ist und hohe Kommunikationsgeschwindigkeiten erreicht werden können. Außerdem sind diese Systeme für einen großen Nutzerkreis anwendbar. Zur Evokation der Potenziale ist eine externe Stimulation erforderlich, die mit der Zeit belästigend und ermüdend auf den Nutzer wirken kann [128]. SSVEPs sind eine natürliche Antwort des Gehirns, ausgelöst durch eine sich wiederholende visuelle Stimulation über 5 Hz. Wird die Netzhaut durch eine visuelle Stimulation mit einer bestimmten Frequenz angeregt, so erzeugt das Gehirn eine elektrische Aktivität mit derselben (oder multiplen) Frequenz(en) des visuellen Stimulus [60]. Als P300 wird eine Komponente eines ereigniskorrelierten Potenzials (engl. Event-Related Potential (ERP)) bezeichnet. Sie ist im EEG als ein positiver Peak erkennbar. Dieser Peak tritt ungefähr 300 ms nach der Präsentation eines seltenen aber für den Nutzer bedeutenden Stimulus, innerhalb einer Serie von regelmäßig auftretenden Stimuli, auf [171].

Die Veröffentlichung [108] beschreibt die Einbindung eines SSVEP- und P300-BCIs zur Steuerung des Assistenzroboters FRIEND. Den Nutzern wird es ermöglicht, das System mit Befehlen auf einer hohen Abstraktionsebene zu steuern und bei einer fehlerhaften Ausführung der Aufgabe korrigierend einzugreifen. In einem solchen Fall erhält der Nut-

zer die Möglichkeit, den Roboterarm mit Befehlen direkt zu steuern, um die Aufgabe zu Ende zu führen. Die Steuerung des Systems auf niedriger Abstraktionsebene erfolgt entweder mit Hilfe des P300- oder des SSVEP-Paradigmas. Bei beiden Methoden erfolgt die Steuerung über eine grafische Benutzeroberfläche. Über diese lässt sich die gewünschte Bewegung sowie die Schrittweite dieser Bewegung einstellen. Der Anwender muss seinen Blick zwischen dem Roboter und dem Monitor wechseln, was eine Bewegungsfähigkeit der Augen oder des Kopfes erforderlich macht. Eine kontinuierliche Bewegung ist mit dem System nicht möglich. Auch ist die Zeit zum Ansprechen des Systems mit dem P300-Paradigma zu groß, um dieses für eine Echtzeitanwendung einsetzen zu können.

Dies wurde auch in der Arbeit [131] festgestellt, wo der Benutzer in der Lage war einen Roboterarm und einen Rollstuhl, durch die Konzentration auf ein bestimmtes Zeichen auf einem Bildschirm, zu steuern. Hier führte das System jedoch die gewünschte Bewegung solange aus, bis entweder ein gegenteiliges oder das Stopp-Kommando übermittelt wurde.

Es hat sich gezeigt, dass mit einem hybriden BCI die Intention des Nutzers besser nachvollzogen werden kann, was zu einer zuverlässigeren, flexibleren und schnelleren Interaktion führt, als dies mit nur einem BCI möglich wäre. Ein hybrides BCI besteht aus einem BCI und wenigstens einem anderen System oder Gerät. Ein solches System oder Gerät kann entweder ein anderes BCI-Paradigma sein, die Ausgabe eines externen Gerätes (Kinnjoystick, Schalter, usw.) oder andere Biosignale (Herzrate, Augenbewegungen, Muskelaktivitäten, usw.) [138].

Die Arbeit [19] stellt einen neuartigen Ansatz zur Positionssteuerung eines Roboterarms mittels eines hybriden BCIs dar. Das System nutzt Bewegungsvorstellungen, P300-Potenziale und Fehlerpotenziale (engl. Error Potentials (ErrPs)) zur Steuerung. Die Bewegungen des Roboterarmes werden durch die Bewegungsvorstellungen des Nutzers hervorgerufen. Durch die Vorstellung der linken bzw. rechten Handbewegung, führt der Roboterarm eine Drehung entgegen bzw. entsprechend dem Uhrzeigersinn durch.



Mit Hilfe der Vorstellung der Füße lässt sich der Roboterarm vorwärts bewegen. Das P300-Potenzial wird erzeugt, sobald der Roboterarm die Zielposition erreicht und der Nutzer diesen zum Stoppen bringen möchte. Die Fehlerpotenziale dienen dem System als Rückmeldung vom Nutzer. Wird ein Fehler während der Bewegung detektiert, so wird die Bewegung rückgängig gemacht. Tritt ein Fehler nach dem Stoppen des Roboterarmes auf, so erfolgt eine Positionskorrektur mittels eines vordefinierten Versatzes. Durch Tests ergab sich eine Erfolgsrate von 95 % zur Erreichung der Zielposition. Eine Steuerung aller Freiheitsgrade ist noch nicht möglich.

## 1.2. Hauptbeiträge der Arbeit

Das Ziel dieser Arbeit besteht in der Untersuchung eines hybriden BCIs zur optimalen Auslegung als HMI. Verschiedene BCI-Ansätze, wie sensomotorische Rhythmen, Alphawellen, Augenartefakte, ereigniskorrelierte und visuell evozierte Potenziale sollen so miteinander kombiniert und ausgelegt werden, dass es der Zielgruppe möglich ist, einen Roboterarm mit sieben Freiheitsgraden (engl. Degrees of Freedom (DOF)) zu steuern (siehe Abbildung 1.1). Den Nutzern des zu entwickelnden Systems soll es möglich sein, alle Freiheitsgrade des Roboters zu kontrollieren, ohne den Blick auf eine grafische Benutzeroberfläche richten zu müssen. Verwendet wird hierfür der am Institut für Automatisierungstechnik (IAT) entwickelte Swift Brain-Computer Interface (sBCI)-Helm [113] (zu sehen in der Abbildung 1.1). Bei diesem Helm handelt es sich um ein neuartiges EEG-Akquisitionssystem für BCIs in Kombination mit einem visuellen Stimulator im Blickfeld des Nutzers, der eine Evokation von ereigniskorrelierten und visuellen Potenzialen ermöglicht. Der Vorteil dieses Systems besteht darin, dass der Nutzer seinen Blick auf den Roboterarm und seine Umgebung richten und gleichzeitig Steuerkommandos senden kann. Ein Wechsel der Blickrichtung, zwischen dem Roboter und einer grafischen Benutzerschnittstelle zur Steuerung des Roboters, ist nicht erforderlich. Das zu entwickelnde System nimmt die Gehirnströme des Nutzers auf, verarbeitet die Signale

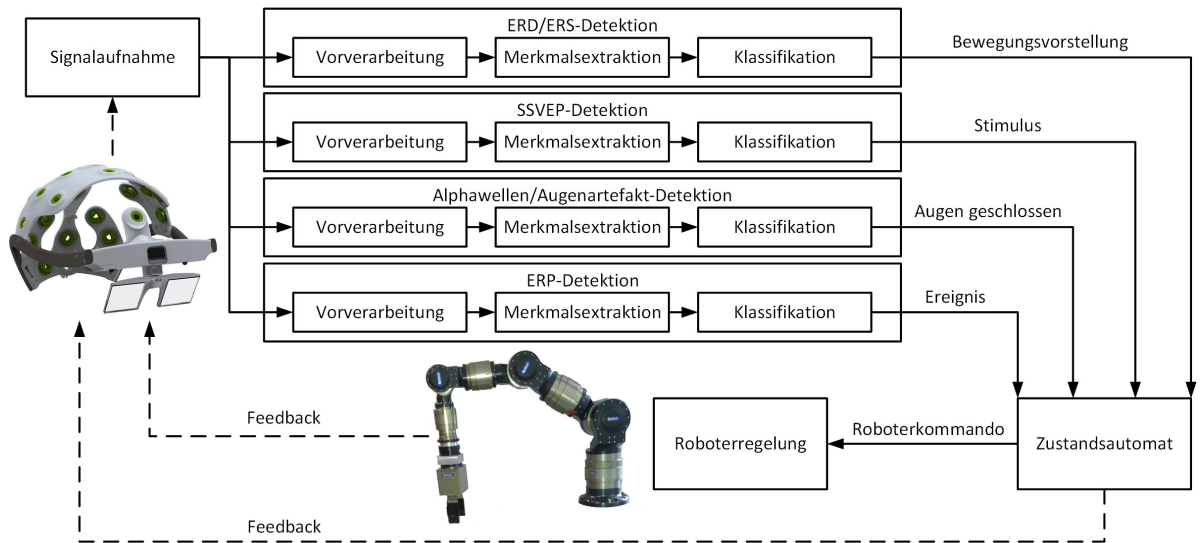


Abbildung 1.1.: Systemübersicht der BCI-basierten Roboterarmsteuerung.

und sendet die klassifizierten Gehirnmuster an einen Zustandsautomaten. Dieser Zustandsautomat ermöglicht einen Wechsel zwischen verschiedenen Steuerungsgruppen des Roboters sowie die Steuerung des Roboters in der ausgewählten Gruppe. Die Regelung des Roboters empfängt die Steuerkommandos des Zustandsautomaten und bringt diese zur Ausführung. Der Anwender erhält eine visuelle Rückmeldung über die ausgeführte Bewegung des Roboters und eine akustische Rückmeldung über den Zustandsautomaten.

Die Hauptbeiträge dieser Arbeit werden im Folgenden beschrieben.

Ein erster Beitrag besteht in der Implementierung eines neuartigen SSVEP-BCIs und P300-BCIs, die zur Stimulation die Leuchtdioden (engl. Light-Emitting Diodes (LEDs)) des sBCI-Helms verwenden. Das SSVEP-BCI kann auf zwei Arten operieren: frequenz- oder phasenbasiert. Bei dem frequenzbasierten Ansatz blinken alle vier LEDs mit einer unterschiedlichen Frequenz. Hingegen blinken die LEDs bei dem phasenbasierten Ansatz zwar mit der gleichen Frequenz, jedoch mit unterschiedlichen Phasen. In der Art eines P300-Spellings leuchten die LEDs bei dem P300-BCI in zufälliger Reihenfolge zeilen- und spaltenweise oder einzeln auf. Alle Modalitäten wurden von jeweils mindestens 8 Pro-

banden getestet und hinsichtlich ihrer Genauigkeit und Informationstransferrate (ITR) verglichen.

Der zweite Beitrag ist ein neuartiges Konzept zur schrittweisen Steuerung eines Roboterarmes über ein hybrides BCI. Mit dem entwickelten SSVEP-BCI und P300-BCI stehen dem Nutzer nur wenige diskrete Kommandos zur Steuerung des Roboters zur Verfügung. Um alle Freiheitsgrade des Roboters steuern zu können, muss dem Nutzer daher ein Zustandsautomat zur Verfügung gestellt werden. Mit dem entwickelten Zustandsautomaten kann der Nutzer zwischen drei Achsen (x, y, und z) wechseln, eine Rotations- oder Translationsbewegung vorgeben, die Schrittweite verändern, ein Inkrementieren oder Dekrementieren des gewählten Freiheitsgrades vornehmen und den Greifer öffnen oder schließen. Ebenfalls ist es möglich, einen Wechsel des Roboter-Koordinatensystems zwischen Basis- und Greiferkoordinaten durchzuführen. Ein Umschalten zwischen den Steuerungsgruppen des Roboters und die Steuerung des Roboters in der ausgewählten Gruppe erfolgt entweder über das SSVEP-BCI oder das P300-BCI. Beide Modalitäten nutzen den visuellen Stimulator des sBCI-Helms. Da die Stimulation mit der Zeit belastigend und ermüdend auf den Nutzer wirkt, lässt sich diese ausschalten und über das ERD/ERS-BCI wieder einschalten. Die Steuerung wurde von 10 Probanden zur Bearbeitung einer Pick-and-Place-Aufgabe eingesetzt und unter objektiven und subjektiven Kriterien evaluiert.

Bei dem dritten Beitrag handelt es sich um die Implementierung eines neuartigen Augenartefakt-HMIs und Alphawellen-BCIs. Beide Systeme detektieren ein Schließen bzw. Geschlossenhalten der Augen und ermöglichen hierüber den Stopp eines Roboterarmes an der Zielposition oder in Gefahrensituationen. Diese beiden Modalitäten und das SSVEP-BCI wurden von jeweils mindestens 10 Probanden getestet und hinsichtlich ihrer Zuverlässigkeit, Genauigkeit und Detektionszeit verglichen.

Die Erweiterung der schrittweisen zu einer geschwindigkeitsbasierten Roboterarmsteuerung stellt den vierten neuartigen Beitrag dieser Arbeit dar. Sobald die Bewegungsrichtung des Roboterarmes vom Nutzer vorgegeben wird, führt dieser die Bewegung so-

lange aus, bis entweder eine andere Richtung vorgegeben oder er über ein Kommando zum Stoppen gebracht wird. Zusätzlich kann der Roboter in Gefahrensituationen auf Kommando des Nutzers anhalten. Ein Stopp-Kommando lässt sich mit dem SSVEP-BCI, dem Alphawellen-BCI und dem Augenartefakt-HMI erzeugen. Der Nutzer kann zwischen mehreren Geschwindigkeiten bei der Ausführung der Bewegungen wählen. Auch diese Steuerung wurde von 10 Probanden zur Bearbeitung einer Pick-and-Place-Aufgabe eingesetzt und unter objektiven und subjektiven Kriterien evaluiert.

Der fünfte Beitrag ist die Implementierung eines neuartigen ErrP-BCIs zur Detektion von Fehlern, die bei der Navigation in dem Zustandsautomaten der Roboterarmsteuerung auftreten können, und eines neuartigen ERP-BCIs zur Detektion des Erreichens und Überschreitens der Zielposition. Anhand der Kalibrierungsdaten von 13 Probanden wurde ermittelt, mit welchen Wahrscheinlichkeiten Fehler korrekt und fehlerhaft klassifiziert werden und ab welchen Genauigkeiten der Einsatz eines ErrP-BCIs in Frage kommt. Das ERP-BCI wurde hinsichtlich seiner Zuverlässigkeit und Genauigkeit mit den anderen Stoppmodalitäten verglichen.

### **1.3. Gliederung der Arbeit**

Diese Arbeit gliedert sich in insgesamt sieben Kapitel.

Im zweiten Kapitel wird zunächst ein Überblick über das grundlegende Konzept eines BCIs geliefert. Dies umfasst die Definition eines BCIs mit seinen Komponenten (Signalaufnahme, Signalverarbeitung und Anwendung), die Bewertung von BCIs und die effektivsten neurophysiologischen Signale für EEG-basierte BCIs (SSVEP, P300, ERD/ERS, Fehlerpotenziale und Alphawellen).

Das sich anschließende dritte Kapitel befasst sich mit dem verwendeten sBCI-System. Hier werden zuerst die Hardwarekomponenten des Systems vorgestellt. Anschließend folgt eine Beschreibung der Algorithmen zur Erkennung von Bewegungsvorstellungen und SSVEPs. Zum Schluss wird das System innerhalb einer Studie getestet. Diese Studie

beinhaltet das Training von Probanden für Bewegungsvorstellungen, die Auswahl von Haushaltsgeräten über Bewegungsvorstellungen und die Steuerung der Geräte mit Hilfe eines SSVEP-BCIs.

Kapitel 4 beinhaltet die Systembeschreibung der schrittweisen Steuerung eines Roboterarmes über ein hybrides BCI. Zu Beginn dieses Kapitels werden die Anforderungen an die Roboterarmsteuerung beschrieben und eine Übersicht über das System geliefert. Es folgt eine Beschreibung des SSVEP-BCIs und des P300-BCIs, welche ein Umschalten zwischen den Steuerungsgruppen des Roboterarmes und eine Steuerung innerhalb der ausgewählten Gruppe ermöglichen. Danach findet eine Beschreibung von zwei unterschiedlichen Zustandsautomaten zur Roboterarmsteuerung statt. Im Anschluss wird die Implementierung der Regelung des Roboters präsentiert. Nach der Beschreibung der einzelnen Komponenten folgt eine Vergleichsstudie der Umschalt- und Steuermodalitäten und der Zustandsautomaten. Anhand der Studie wird gezeigt, welche Modalität und welcher Zustandsautomat am geeignetsten für eine Roboterarmsteuerung sind. Zum Schluss wird die Steuerung anhand einer Pick-and-Place-Aufgabe getestet und evaluiert.

Eine Systembeschreibung der geschwindigkeitsbasierten Steuerung eines Roboterarmes über ein hybrides BCI befindet sich in Kapitel 5. Nach einer Beschreibung der Systemanforderungen und dem Überblick über das System, werden das Alphawellen-BCI und das Augenartefakt-HMI vorgestellt. Beide Systeme ermöglichen einen Stopp des Roboterarmes an der Zielposition und in Gefahrensituationen. Danach folgt eine Vergleichsstudie der Stoppmodalitäten. Zusätzlich zu den beiden genannten Systemen wird das SSVEP-BCI aus Kapitel 4 und das ERP-BCI aus Kapitel 6 getestet. Anhand der Studie wird gezeigt, welche Modalität am geeignetsten für einen Stopp des Roboterarmes ist und welche Geschwindigkeiten zu wählen sind. Zum Schluss wird die Steuerung anhand einer Pick-and-Place-Aufgabe getestet und evaluiert. Im Rahmen der Evaluierung findet ein Vergleich mit der schrittweisen Roboterarmsteuerung statt.

Verfahren zur Detektion und Korrektur von Fehlern behandelt das sechste Kapitel. Zuerst wird ein System zur Detektion und Korrektur von Klassifikationsfehlern beschrie-

ben, die bei der Navigation in dem Zustandsautomaten der Roboterarmsteuerung auftreten. Abschließend wird ein System vorgestellt, das ein Überschreiten der Zielposition feststellen und korrigieren kann.

Zum Schluss fasst das siebte Kapitel die Ergebnisse der Arbeit zusammen und liefert einen Ausblick.

## **Kapitel 2.**

# **Brain-Computer Interfaces (BCIs)**

Dieses Kapitel liefert einen Überblick über das Forschungsgebiet der nicht-invasiven BCIs. Das Kapitel beginnt mit der Definition eines BCIs und beschreibt den Stand der Forschung seiner einzelnen Komponenten. Als erste Komponente wird die Messung der Gehirnaktivität beschrieben. Es folgt eine Beschreibung der Signalverarbeitung, die die aufgenommenen Gehirnsignale in Steuerkommandos übersetzt. Danach werden Anwendungen vorgestellt, die die Steuerkommandos verwenden. Im Anschluss wird die Bewertung von BCIs erläutert. Zum Schluss erfolgt eine Präsentation der effektivsten neurophysiologischen Signale, die bei BCIs Verwendung finden.

## **2.1. Definition eines BCIs**

Die BCI-Forschung begann Anfang der 70er Jahre des 20. Jahrhunderts durch die Arbeit von Dr. Jacques Vidal, dem Direktor des Brain-Computer Interface Labors an der Universität von Kalifornien. Es war der erste erfolgreiche Versuch, Gehirnsignale für eine Mensch-Computer Kommunikation zu verwenden. Vidal führte die Definition einer direkten Gehirn-Computer Kommunikation ein und zeigte dessen Möglichkeiten und Grenzen auf [176]. Im Jahre 1977 stellte er ein BCI vor, das visuell evozierte Potenziale für eine zweidimensionale Steuerung eines Zeigers durch ein Labyrinth nutzt [177].

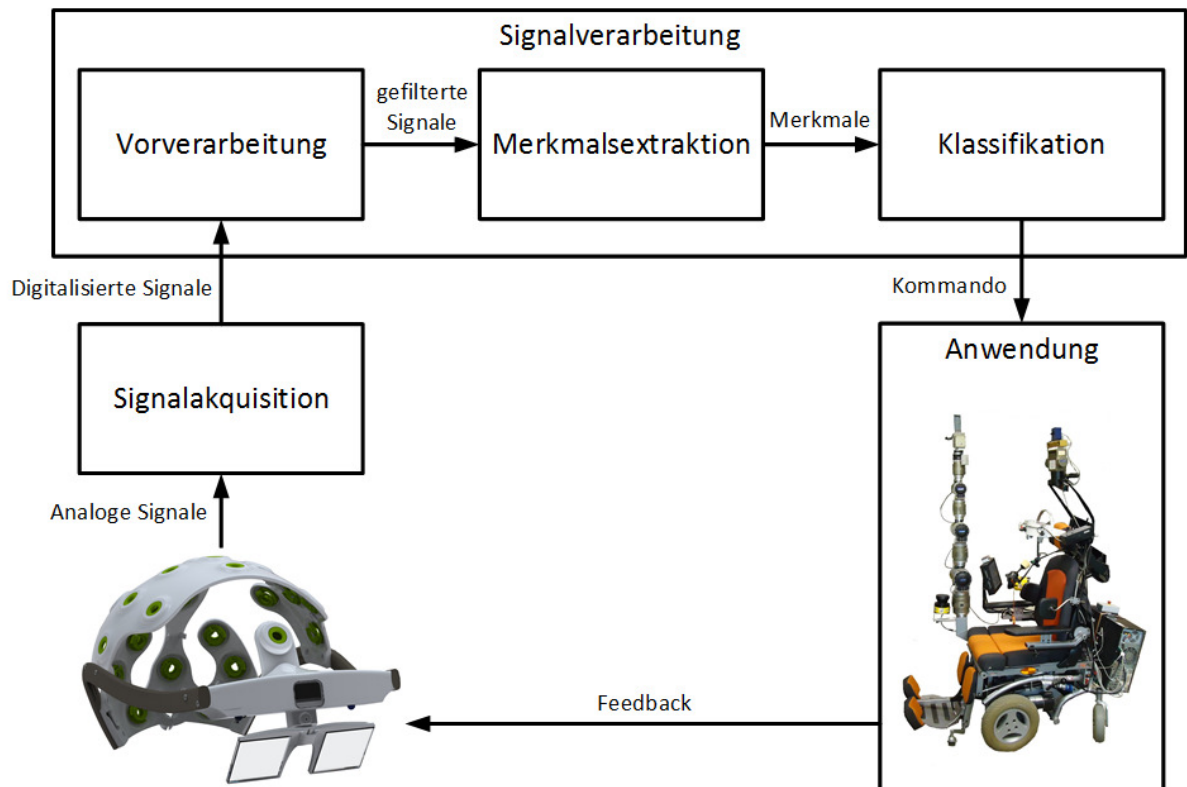


Abbildung 2.1.: Die Komponenten eines BCIs (nach [186]).

Während der ersten internationalen Konferenz der BCI-Forschung im Jahre 1999 wurde der Begriff eines BCIs definiert. Demnach ist ein BCI ein Kommunikationssystem, das nicht von den normalen Ausgangspfaden des Gehirns, den peripheren Nerven und Muskeln abhängt [185].

Jedes BCI besteht aus vier Komponenten: den aufgenommenen Gehirnsignalen des Nutzers als Eingang, einem Algorithmus, der die Signale in Steuerbefehle konvertiert, einem Ausgang, der die Kommandos zur Steuerung einer Anwendung benutzt und einem Protokoll, das beschreibt, wie die Komponenten miteinander interagieren [186]. Die Abbildung 2.1 zeigt das grundlegende Design eines BCIs.

Je nach der Art der Signableitung wird zwischen invasiven und nicht-invasiven BCIs unterschieden. Nicht-invasive BCIs messen die neuronale Aktivität von der Kopfober-



fläche, wohingegen invasive BCIs die Signale von der Hirnrinde oder direkt von dem kortikalen Gewebe ableiten [5].

Zusätzlich wird zwischen exogenen und endogenen BCIs unterschieden. Die exogenen BCIs benötigen eine externe Stimulation, die akustisch, visuell oder taktil sein kann, um eine bestimmte Hirnaktivität zu erzeugen. Im Gegensatz dazu benötigen endogene BCIs keinen äußeren Reiz, sondern eine bestimmte mentale Aufgabe, um ein Signalmuster zu erzeugen [128].

Ein BCI kann entweder synchron oder asynchron operieren. Synchrone BCIs analysieren die Hirnsignale in vordefinierten Zeitfenstern. Durch eine kontinuierliche Analyse der Hirnsignale lässt sich ein asynchrones BCI realisieren [137].

Wird ein BCI mit einem anderen System oder Gerät kombiniert, handelt es sich um ein hybrides BCI. Das zu kombinierende System oder Gerät kann entweder ein anderes BCI-Paradigma sein, die Ausgabe eines externen Gerätes (Kinnjoystick, Schalter, usw.) oder andere Biosignale (Herzrate, Augenbewegungen, Muskelaktivitäten, usw.) [138].

## 2.2. Messung der Gehirnaktivität

Zur Messung der Gehirnaktivität kommen eine Reihe von Messmethoden zum Einsatz [155]. Am häufigsten nutzen BCIs die vom Gehirn produzierten elektrischen Signale, aber auch magnetische oder metabolische Signale finden Verwendung [128]. Die Aufnahme der Signale kann von vier Positionen aus erfolgen. Die Sensoren können ohne Kontakt zum Körper stehen, wie bei der Magnetenzephalographie (MEG) oder der funktionellen Magnetresonanztomographie (fMRT). Auch können sich die Sensoren auf der Kopfhaut befinden, wie bei der Elektroenzephalographie (EEG) oder der funktionellen Nahinfrarotspektroskopie (fNIRS). Weiterhin kann die Messung mit Hilfe von Elektrokortikographie (ECoG)-Elektroden erfolgen, die sich auf der Hirnoberfläche befinden. Über Mikroelektroden findet eine intrakortikale Messung innerhalb des Gehirns statt, indem die Elektroden in den Kortex implantiert werden. BCIs, die die Signale

von der Oberfläche des Gehirns oder innerhalb des Kortexes ableiten, werden als invasive BCIs bezeichnet. Ist kein chirurgischer Eingriff erforderlich, handelt es sich um ein nicht-invasives BCI [5].

Jede Messmethode hat ihre Vor- und Nachteile. Die invasiven Methoden liefern eine höhere räumliche Auflösung, stärkere Signale und einen größeren Frequenzbereich als nicht-invasive Methoden. Andererseits ist bei invasiven Messungen ein chirurgischer Eingriff erforderlich, es besteht die Gefahr von Infektionen und regelmäßige medizinische Untersuchungen sind notwendig [5]. fNIRS und fMRT messen Veränderungen in den hämodynamischen Antworten des Gehirns. Sie liefern zwar eine hohe räumliche, jedoch eine geringe zeitliche Auflösung. MEG ist eine Technik, die die magnetische Aktivität des Gehirns aufnimmt. Sowohl ihre zeitliche als auch räumliche Auflösung ist hoch. Die Nachteile von MEG und fMRT bestehen in ihrem hohen technischen Aufwand und ihren hohen Kosten. EEG-Messungen erfolgen über Elektroden auf der Kopfhaut. Die Messung ist einerseits sehr leicht durchzuführen und besitzt eine hohe zeitliche Auflösung, jedoch sind die räumliche Auflösung und der Frequenzbereich relativ gering [187]. Zurzeit basieren die meisten BCIs auf einer EEG-Messung der Gehirnaktivität [116]. Da in dieser Dissertation die BCI-basierte Roboterarmsteuerung EEG-Signale verwendet, wird im folgenden Abschnitt näher auf diese Art der Messung eingegangen.

### **2.2.1. Elektroenzephalographie (EEG)**

Die EEG ist ein Verfahren zur Ableitung der Gehirnaktivität und wurde erstmals von dem Psychiater Hans Berger im Jahre 1929 beschrieben [17].

Netzwerke von kortikalen neuronalen Zellbaugruppen sind die Hauptgeneratoren von EEG-Signalen. Wenn ein Neuron von anderen Neuronen über Aktionspotenziale angeregt wird, werden exzitatorische postsynaptische Potenziale (EPSP) erzeugt. Diese entstehen auf dem apikalen dendritischen Baum einer kortikalen Pyramidenzelle. Es fließt ein Strom von der nicht erregten Membran der Soma und Basaldendriten zum apikalen dendritischen Baum. Die dendritischen Stämme der Pyramidenzellen sind parallel

angeordnet und zeigen senkrecht zur kortikalen Oberfläche. Aufgrund der räumlichen Anordnung und der gleichzeitigen Aktivierung einer großen Population von Pyramidenzellen, kommt es zu einer räumlich-zeitlichen Überlagerung der Zellenaktivitäten. Das Ergebnis ist ein Stromfluss, der detektierbare EEG-Signale erzeugt [9].

### 2.2.1.1. Ableitung der Signale

Die Ableitung der EEG-Signale erfolgt über Elektroden auf der Kopfhaut. Die Elektroden bestehen überwiegend aus Silber/Silberchlorid (Ag/AgCl) [173]. Um ein sauberes Signal aufnehmen zu können, müssen die Impedanzen zwischen Elektrode und Kopfhaut unter  $5\text{ k}\Omega$  liegen. Dies wird mit Hilfe eines Elektrolytgels erreicht, welches zwischen Elektrode und Kopfhaut aufgebracht wird. Vor oder während des Auftragens des Gels wird die oberste Schicht der Kopfhaut mechanisch aufgeraut oder abgetragen, um die Impedanz zu minimieren [163]. Trockene Elektroden benötigen kein Gel und bestehen aus Materialien wie Titan oder Edelstahl [55].

Eine Messung benötigt eine oder mehrere Messelektroden, eine Referenzelektrode und eine Groundelektrode. Um ein Signal zu erhalten, werden eine Messelektrode und die Referenzelektrode an den beiden Eingängen eines Differenzverstärkers angeschlossen. Die Groundelektrode wird mit dem internen Ground des Differenzverstärkers verbunden. Die aufgenommene Spannung besitzt eine Größenordnung von wenigen  $\mu\text{V}$ . Neben den Gehirnsignalen werden auch biologische (z.B. Zungen- und Augenbewegungen) und technische Artefakte (z.B. Netzrauschen) aufgenommen, die die Gehirnsignale überlagern. Analoge Filter ermöglichen eine Unterdrückung der Artefakte. Zur Entfernung von Frequenzen über 50-100 Hz kommen Tiefpassfilter und unter 0,5 Hz Hochpassfilter zum Einsatz. Zusätzlich kann ein Kerbfilter (engl. Notch-Filter) den Einfluss der Netzfrequenz (50/60 Hz) unterdrücken. Die Ausgangsspannung wird verstärkt und an einen Analog-Digital-Konverter weitergeleitet. Dort wird das analoge Signal mit einer Frequenz, die das Nyquist-Kriterium erfüllen muss, abgetastet und in ein digitales Signal konvertiert. Zum Schluss lassen sich die Signale visualisieren und weiter verarbeiten [130].




Abbildung 2.2.: Das internationale 10-20-System gesehen von der linken Seite des Kopfes (a) und über dem Kopf (b) [114].

Die Elektrodenpositionen sind über das internationale 10-20-System festgelegt [82]. Das 10-20-System benutzt zwei Referenzpunkte zur Bestimmung der Elektrodenpositionen. Einer dieser Punkte ist der Nasion, der sich über der Nase und auf der gleichen Höhe wie die Augen befindet. Der andere Referenzpunkt ist der Inion, ein knöcherner Höcker am Hinterkopf. Die Elektrodenpositionen ergeben sich aus den Intervallen von 10 und 20 % des Abstandes zwischen den beiden Referenzpunkten (Abbildung 2.2). Jede Gehirnregion ist mit einem Buchstaben versehen. Der Buchstabe *A* repräsentiert das Ohr, *P<sub>g</sub>* den Nasenrachen, *C* den zentralen und *F<sub>p</sub>* den frontalen-polaren Bereich. Die Buchstaben *F*, *T*, *P* und *O* stehen für den Frontal-, Temporal-, Parietal- und Okzipitallappen. Positionen auf der linken Gehirnhälfte besitzen ungerade Nummern. Hingegen besitzen die Positionen auf der rechten Gehirnhälfte gerade Nummern. Der Buchstabe *Z* steht für Elektroden auf der Mittellinie.

### 2.2.1.2. Frequenzbereiche

Das Elektroenzephalogramm (EEG) ist die visuelle Darstellung der aufgenommenen Signale, die sich hinsichtlich ihrer Frequenz unterscheiden. Entsprechend ihrer biologischen Bedeutung und ihrer Verteilung über der Kopfhaut lassen sich fünf Frequenzbereiche definieren. In der Literatur variieren die Grenzen der Frequenzbereiche, die prinzipielle Einteilung ist jedoch gleich.

Im Frequenzbereich von 0,5 bis 4 Hz liegen Deltawellen ( $\delta$ ). Sie sind nur während des Tiefschlafes oder einer Anästhesie vorhanden. Eine erhöhte Aktivität im Wachzustand von Erwachsenen ist unnatürlich und hat ihre Ursache in einer neurologischen Krankheit [95].

Thetawellen ( $\theta$ ) befinden sich zwischen 4 und 8 Hz und dominieren im EEG während des Schlafes. Während des Wachzustandes sind nur wenige Frequenzen bei Erwachsenen aufzuzeichnen. Eine erhöhte Aktivität im Wachzustand von Erwachsenen ist unnatürlich und hat ihre Ursache in einer neurologischen Krankheit. Bei Kleinkindern ist eine erhöhte Aktivität im Wachzustand dagegen normal [95]. Weiterhin tritt eine verstärkte Aktivität bei einer Meditation auf [1].

Alphawellen ( $\alpha$ ) sind über dem okzipitalen Bereich des Gehirns zu beobachten. Sie liegen in einem Frequenzbereich von 8 bis 12 Hz. Ein Anstieg ihrer Amplituden tritt auf, wenn eine Person wach und entspannt ist und die Augen geschlossen hält. Sobald die Augen geöffnet werden und eine mentale Anstrengung stattfindet, tritt eine Abschwächung der Amplituden auf [62]. My-Rhythmen ( $\mu$ ) liegen in dem selben Frequenzbereich, werden jedoch über dem sensomotorischen Kortex gemessen. Sie treten auf, sofern keine Bewegung vorgestellt oder durchgeführt wird [144].

Die Betawellen ( $\beta$ ) liegen zwischen 12 und 30 Hz und sind mit Aufmerksamkeit, Wahrnehmung und Kognition verbunden [90]. Eine Veränderung der Aktivität kann bei der Bewegungsvorstellung und -ausführung über dem sensomotorischen Kortex festgestellt werden [118].

Gammawellen ( $\gamma$ ) befinden sich in einem Frequenzbereich über 30 Hz. Diese Art von Aktivität steht ebenfalls in Verbindung mit Aufmerksamkeit, Wahrnehmung und Kognition [90].

## 2.3. Signalverarbeitung

Nach der Aufnahme der Signale folgt die Signalverarbeitung, die die Signale in entsprechende Steuerbefehle übersetzt. Zuerst findet eine Vorverarbeitung der Signale statt, um die räumliche Auflösung und das Signal-Rausch-Verhältnis (engl. Signal-to-Noise Ratio (SNR)) zu verbessern. Anschließend erfolgt die Extraktion und Auswahl relevanter Merkmale. Zum Schluss weist der Klassifikator die Merkmale einer Klasse zu und übersetzt diese somit in einen Steuerbefehl für das Anwendungsprogramm.

### 2.3.1. Vorverarbeitung

Als erster Schritt findet eine Vorverarbeitung statt, um eine Verbesserung der Signale zu erreichen. Die Wahl der Methode hängt von mehreren Faktoren ab. Zu diesen zählen die Aufnahmetechnologie, die Anzahl an Elektroden und die zu verarbeitenden neurophysiologischen Signale.

Basierend auf das verwendete BCI-Paradigma kann eine Einschränkung des zu betrachtenden Frequenzbereiches hilfreich sein. In diesem Fall kommen digitale Frequenzfilter, mit endlicher oder unendlicher Impulsantwort, zum Einsatz. Eine Alternative bietet die Fourier-basierte Filterung [39].

Die räumliche Auflösung ist bei einer EEG-Messung gering. Daher stellt die Aufnahme eines Signals von einem bestimmten kortikalen Bereich ein Problem dar. Jede Elektrode nimmt verschiedene Signale innerhalb einer Nachbarschaft von wenigen cm auf, die sich überlagern. Das Ziel einer räumlichen Filterung besteht darin, das Signal einer bestimm-

ten Quelle zu erhalten. Ein räumlicher Filter ist ein Vektor mit Gewichten, der eine Linearkombination der Elektrodensignale spezifiziert [39]. Zur räumlichen Filterung kommen häufig die Methoden Common Average Reference (CAR), Common Spatial Pattern (CSP), Principal Component Analysis (PCA) und Independent Component Analysis (ICA) sowie Laplace-Filter zum Einsatz [15].

Bei der Methode CAR wird der Mittelwert aller EEG-Kanäle von den einzelnen Kanälen subtrahiert. Der Einfluss von weit entfernten Quellen wird dadurch zwar reduziert, jedoch können Artefakte von einem Kanal ebenfalls in anderen Kanälen auftauchen [39].

Die erste Methode zur Laplace-Filterung stammt von Hjorth (1975) [71]. Diese Methode subtrahiert den Mittelwert der vier benachbarten Elektroden von der Elektrode im Zentrum.

CSP ist eine Technik zur Analyse von Daten basierend auf Aufnahmen zweier Klassen. Das Ziel dieser Technik ist ein Filter, der die Varianz der EEG-Signale für eine Klasse maximiert und gleichzeitig für die andere Klasse minimiert [91].

PCA wird zur multivariaten Datenanalyse und zur Dimensionsreduktion eingesetzt. Es ist eine orthogonale Transformation des Koordinatensystems, in dem die Daten beschrieben sind. Die neuen Koordinatenwerte werden als Hauptkomponenten (engl. Principal Components) bezeichnet. Die erste Hauptkomponente besitzt die größte Varianz und jede nachfolgende Komponente die nächstgrößere Varianz unter der Bedingung, dass sie orthogonal zu der vorangegangenen Komponente ist [192].

Das Ziel der Methode ICA ist die Wiederherstellung unabhängiger Quellen aus Sensordaten. Die zu analysierenden Daten sind eine unbekannte lineare Vermischung der nicht beobachtbaren unabhängigen Quellen. Die statistische Abhängigkeit der Signale wird reduziert, um die Signale so unabhängig wie möglich voneinander zu machen [102].

### 2.3.2. Merkmalsextraktion

Nach der Vorverarbeitung findet die Extraktion von Merkmalen aus den vorverarbeiteten Signalen statt. Die dafür zu verwendende Methode hängt von den zugrunde liegen-

den neurophysiologischen Signalen ab. Viele Arbeiten nutzen Parameter aus dem Zeit- und/oder Frequenzbereich und parametrische Modellierungen [15].

Im Zeitbereich kommen Methoden wie Flächenberechnung, Peak-Picking und Template-Matching zum Einsatz. Zur Detektion des P300-Potenzials wird, in einem festgelegten Zeitfenster, die Fläche zwischen dem Signal und einer Basislinie berechnet (Flächen-Methode) oder die Differenz zwischen dem niedrigsten Punkt vor und dem höchsten Punkt innerhalb des Zeitfensters bestimmt (Peak-Picking-Methode) [119]. Die Template-Matching-Methode sucht nach spezifischen Merkmalen mittels zuvor bestimmter Referenzsignale (Templates). Jedes Template beinhaltet die bekannten Signale für eine bestimmte Intention des Nutzers. Die Intention des Nutzers wird durch Korrelation der EEG-Signale mit den Templates bestimmt [27].

Frequenzbasierte Merkmale lassen sich über eine Fourier-Transformation extrahieren. Diese Art der Extraktion ist einfach anzuwenden, nicht sehr rechenintensiv und ermöglicht eine direkte Interpretation der Ergebnisse. Ungefähr ein Drittel aller BCIs nutzen Merkmale aus der spektralen Leistungsdichte [15].

Eine Kombination aus Zeit- und Frequenzinformationen liefert die Zeit-Frequenzdarstellung. Hierbei wird ein eindimensionales Signal in eine zweidimensionale Darstellung überführt. Diese Darstellung ermöglicht eine Analyse des spektralen Inhalts des Signals über die Zeit. Die Berechnung der Merkmale erfolgt über eine Wavelet-Transformation [149].

Zu der parametrischen Modellierung von Signalen gehören adaptive autoregressive (AAR)-Modelle. Das Modell wird dabei kontinuierlich an die aktuellen EEG-Signale angepasst. Die Ordnung des Modells ist ein zuvor festzulegender Parameter. Die Koeffizienten des Modells stellen die zu klassifizierenden Merkmale dar [69].

Nach der Merkmalsextraktion kann eine Auswahl von Merkmalen erfolgen. Das Ziel ist eine Reduzierung der Merkmale, damit die Klassifikation nur die nützlichen Merkmale verwendet. Experimente haben gezeigt, dass dies zu einer Verbesserung der Klas-



sifikationsgenauigkeit führt [147]. Zu viele Merkmale sind aufgrund des „Fluchs der Dimensionalität“ zu vermeiden. Darunter ist zu verstehen, dass mit steigender Dimensionalität des Merkmalsvektors, die benötigte Anzahl an Trainingsdaten exponentiell ansteigt [81]. Häufig wird PCA zur Reduzierung der Merkmale eingesetzt [15].

### 2.3.3. Klassifikation

Die extrahierten Merkmale dienen als Eingabe für einen Klassifikator. Dieser nutzt Merkmale mit bekannter Klassenzugehörigkeit zum Training. Nach dem Training ist der Klassifikator in der Lage, Merkmale einer Klasse zuzuordnen. Jede Klasse steht für ein Steuerkommando, das nach der Klassifikation an ein Anwendungsprogramm gesendet wird. Zu denen in der BCI-Forschung am häufigsten eingesetzten Klassifikatoren gehören die lineare Diskriminanzanalyse (LDA), Support Vector Machines (SVMs), neuronale Netze (NN) und schwellwertbasierte Klassifikatoren [15].

Die LDA verwendet Hyperebenen zur Trennung der Merkmale der verschiedenen Klassen. Bei einem Zwei-Klassen Problem ist die Klassenzugehörigkeit eines Merkmalsvektors davon abhängig, auf welcher Seite der Hyperebene sich der Vektor befindet. Die Hyperebene wird so gewählt, dass die Distanz zwischen den beiden Klassenmittelwerten bzw. die Intervarianz maximiert und die Distanz der Datenpunkte zu ihren Klassenmittelwerten bzw. die Intravarianz minimiert wird [58].

Eine SVM nutzt ebenfalls eine Hyperebene zur Klassifikation. Die Hyperebene wird hier jedoch so gewählt, dass die Distanz zu den am nächsten gelegenen Trainingspunkten, den sogenannten Unterstützungsvektoren (engl. Support Vectors), maximiert wird. Neben den linearen lassen sich auch nichtlineare Entscheidungsgrenzen erstellen. Dies erfolgt mit dem „Kernel-Trick“. Dabei transformiert eine Kernel-Funktion die Daten in einen höherdimensionalen Raum. Zu den Funktionen zählt z.B. die Gaußsche Radial Basis Function (RBF) [29].

Liegen mehr als zwei Klassen vor, so kommt entweder die „One-Versus-Rest“- oder die „One-Versus-One“-Strategie zum Einsatz. Nach der ersten Strategie wird immer

eine Klasse von allen anderen Klassen getrennt. Bei der anderen Strategie wird für jedes Klassenpaar ein Klassifikator erstellt [157].

Ein NN ist eine Ansammlung von mehreren künstlichen Neuronen, die die Erstellung von nichtlinearen Entscheidungsgrenzen ermöglichen. Zu den NN gehört z.B. das Multi-Layer Perceptron (MLP). Ein MLP besteht aus mehreren Schichten von Neuronen: einer Eingangsschicht, einer oder mehreren versteckten Schichten und einer Ausgangsschicht. Jeder Eingang eines Neurons ist mit dem Ausgang eines Neurons der vorherigen Schicht verbunden. Die Neuronen der Ausgangsschicht bestimmen die Klassenzugehörigkeit der Eingangsmerkmale [20].

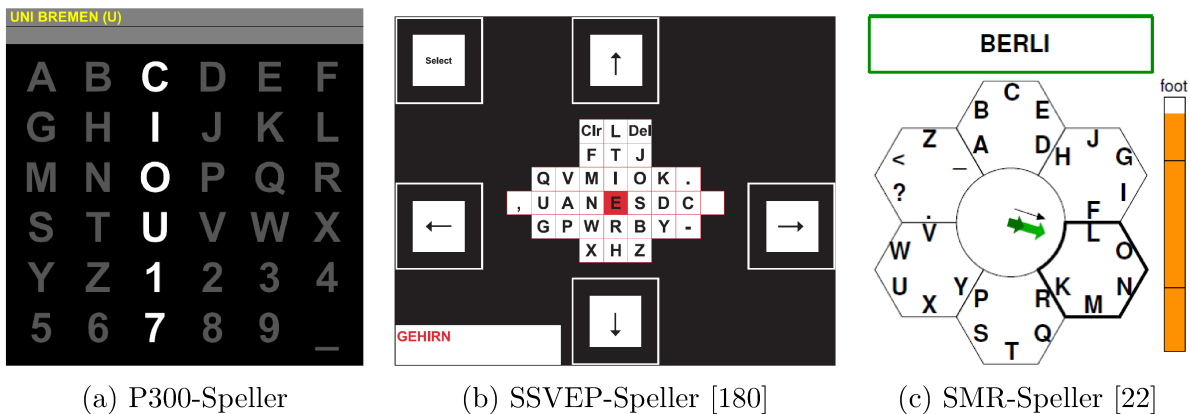
Schwellwerte ermöglichen eine Reduzierung der Fehlalarmrate. Erst wenn die Wahrscheinlichkeit einer Klassifikation über einem Schwellwert liegt, erfolgt die Weiterleitung an das Anwendungsprogramm. Andernfalls wird das Ergebnis verworfen [180].

## **2.4. Anwendungsprogramme**

Die von der Signalverarbeitung kommenden Kommandos dienen der Steuerung einer BCI-Anwendung. Diese Art von Anwendung ist in erster Linie für behinderte Menschen gedacht, um ihre Lebensqualität zu verbessern und den Arbeitsaufwand sowie die Kosten für Pflegepersonal zu reduzieren.

Sind die Menschen fast vollständig gelähmt und können nur noch wenige willentliche Bewegungen ausführen, wie z.B. die Bewegungen der Augen, der Augenlider oder der Lippen, so befinden sie sich im Locked-In State (LIS). Menschen, die über keine motorischen Fähigkeiten verfügen, befinden sich im Completely Locked-In State (CLIS) [94].

Die folgenden Abschnitte präsentieren BCI-Anwendungen aus den Bereichen Kommunikation, Umgebungssteuerung, Fortbewegung und Wiederherstellung der motorischen Funktion. Abschließend wird auf Anwendungen für gesunde Nutzer eingegangen.



(a) P300-Speller

(b) SSVEP-Speller [180]

(c) SMR-Speller [22]

Abbildung 2.3.: Graphische Benutzeroberflächen BCI-basierter Kommunikationsanwendungen. Die Anwendungen unterscheiden sich je nach Art der verwendeten neurophysiologischen Signale.

### 2.4.1. Kommunikation

Menschen mit Behinderungen, die die Kommunikation betreffen, sind oft nicht mehr in der Lage mit Menschen zu kommunizieren. Eine Möglichkeit der Kommunikation liefern in diesem Fall Buchstabierprogramme, auch Speller genannt. Diese Anwendungen zeigen dem Nutzer eine virtuelle Tastatur auf einem Bildschirm. Mit Hilfe eines BCIs kann der Anwender Zeichen auswählen und somit kommunizieren. Die Speller unterscheiden sich je nach Art der verwendeten neurophysiologischen Signale.

Die ersten BCI-Kommunikationsprogramme basierten auf dem P300-Signalmuster [45]. Die zu kommunizierenden Zeichen befinden sich innerhalb einer Matrix, deren Zeilen und Spalten abwechselnd und in zufälliger Reihenfolge aufleuchten (Abbildung 2.3a). Möchte der Anwender ein Zeichen auswählen, so muss er sich auf dieses konzentrieren und in Gedanken das Aufleuchten des Zeichens zählen. Bei jedem Aufleuchten der entsprechenden Zeile und Spalte entsteht ein P300-Potenzial im EEG. Nach einer Mittelung der Signale, über mehrere Wiederholungen, lässt sich das P300-Potenzial für eine Zeile und Spalte detektieren und somit das dazugehörige Zeichen auswählen. In einem Versuch betrug die durchschnittliche Kommunikationsrate 4,68 Zeichen pro Minute [171].

In der Arbeit [180] wird ein SSVEP-Speller beschrieben, der die Zeichen in einer bestimmten geometrischen Anordnung präsentiert (Abbildung 2.3b). Über fünf Kommandos (oben, unten, links, rechts und auswählen) kann der Nutzer ein Zeichen auswählen. Die Kommandos befinden sich in Form von blinkenden Feldern auf der grafischen Benutzeroberfläche. Jedes Feld blinkt mit einer unterschiedlichen Frequenz. Sobald der Anwender seine Konzentration auf eines der Felder richtet, erhöht sich die Amplitude der entsprechenden Frequenz im EEG. Steigt die Amplitude über einen vorher festgelegten Schwellwert, wird der mit dem Feld verknüpfte Befehl ausgeführt. In einer Studie erreichten die Probanden eine mittlere Kommunikationsrate von ca. 8 Zeichen pro Minute [178].

Eine weitere Kommunikationsmöglichkeit liefert der Hex-o-Spell, der über Bewegungsvorstellungen bedient wird. Die Zeichen dieses Spellers sind zu Gruppen in einem Hexagon angeordnet (Abbildung 2.3c). Über die Bewegungsvorstellung der rechten Hand lässt sich der Zeiger in der Mitte des Hexagons im Uhrzeigersinn bewegen. Sobald der Zeiger auf eine Zeichengruppe zeigt, die der Anwender auswählen möchte, muss dieser sich die Bewegung des rechten Fußes vorstellen. Der Zeiger stoppt in diesem Fall und wird größer, je länger die Vorstellung anhält. Erreicht der Zeiger das angrenzende Feld, ordnen sich die Zeichen aus der ausgewählten Gruppe ebenfalls zu einem Hexagon an. In dieser zweiten Phase kann der Nutzer das Zeichen auswählen. Die Auswahl erfolgt mit der gleichen Methode wie zuvor. Die Kommunikationsrate lag in einem Versuch zwischen 2,3 und 7,6 Zeichen pro Minute [22].

### 2.4.2. Umgebungssteuerung

Menschen mit schweren motorischen Behinderungen sind oft nicht in der Lage, selbstständig Geräte zu bedienen. Ein BCI ermöglicht diesen Menschen einen gewissen Grad an Autonomie, was zu einer Verbesserung der Lebensqualität führt. Außerdem erfolgt eine Entlastung von Pflegepersonal und eine Reduzierung von Kosten.

Neben den Kommunikationsanwendungen, die ein Schreiben am Computer ermöglichen, existieren auch Möglichkeiten der Cursor-Steuerung. Als neurophysiologische Signale kommen hierbei SSVEPs [172], SMR [188] oder P300-Potenziale [143] zum Einsatz. Außerdem gibt es hybride Ansätze, die mehrere Paradigmen kombinieren. Es gibt bereits Kombinationen von SSVEPs und SMR [3] sowie P300 und SMR [104].

Die Steuerung von Haushaltsgeräten kann ebenfalls über ein BCI stattfinden. Der in dieser Dissertation verwendete sBCI-Helm ermöglicht die Bedienung eines Radios, einer Mikrowelle und eines Kühlschranks [113]. Die Auswahl der Geräte erfolgt über Bewegungsvorstellungen und die Bedienung der Geräte mit Hilfe von SSVEPs. In Abschnitt 3.3 wird das System zur Steuerung von Haushaltsgeräten eingesetzt und getestet.

### 2.4.3. Fortbewegung

Mittels eines BCIs können sich Menschen mit physischen Beeinträchtigungen autonom in einem Rollstuhl fortbewegen.

Bei einer direkten Steuerung sendet der Nutzer Kommandos an den Rollstuhl, damit dieser eine translatorische oder rotatorische Bewegung ausführt. Die Arbeit [168] setzte eine solche Art der Steuerung mit einem SSVEP-basiertem BCI und einem endlichen Zustandsautomaten um. Aufgrund der zu langen Zeitdauer für die Detektion eines Kommandos, war das verwendete BCI zu langsam, um den Rollstuhl effektiv bedienen zu können.

Eine weitere Möglichkeit der Rollstuhlsteuerung besteht darin, dass das System selbstständig zu vordefinierten Zielen fährt. Mit dem System der Arbeit [152] erfolgt die Lokalisation des Rollstuhls über Barcodes, die sich entlang der zu fahrenden Pfade befinden. Über ein P300-basiertes BCI kann der Fahrer die Ziele auswählen. Der Nachteil dieses Systems besteht darin, dass es wenig flexibel ist und nicht auf Veränderungen in der Umgebung reagieren kann. Eine dynamische Anpassung an die Umgebung lässt sich mit Hilfe von Sensoren realisieren [79].

Auch können der Mensch und das System eine gemeinsame Steuerung des Rollstuhls durchführen. Nach dem Konzept der Arbeit [142] steuert der Mensch auf mentalem Wege den Rollstuhl direkt. Droht eine Kollision mit einem Hindernis, wird dies mit Hilfe von Sensoren detektiert. In diesem Fall übernimmt das System die Steuerung.

#### **2.4.4. Wiederherstellung der motorischen Funktion**

Eine Wiederherstellung der Greifbewegung ist bei Tetraplegikern mit Hilfe der Funktionalen Elektrostimulation (FES) möglich. Bei der FES bewirken elektrische Ströme eine Muskelkontraktion. In der Studie [140] diente die Bewegungsvorstellung der Füße als Steuersignal für die FES. Hierdurch war ein Tetraplegiker in der Lage, einen Zylinder mit der gelähmten Hand zu greifen.

Die FES besitzt den Nachteil, dass der Patient über Restbewegungen verfügen muss, was bei einigen Patienten nicht mehr der Fall ist. In diesem Fall bietet sich eine rein BCI-basierte Steuerung an. Über die Bewegungsvorstellungen der rechten Hand und der beiden Füße war ein Tetraplegiker in der Lage, eine Handorthese zu öffnen und zu schließen [139]. Eine weitere Arbeit nutzte SSVEPs zur Steuerung einer Handprothese [124]. Über vier LEDs konnten die Patienten eine Rotation der Hand nach links oder rechts sowie ein Öffnen oder Schließen der Hand bewirken.

#### **2.4.5. Anwendungen für gesunde Nutzer**

Die BCI-Technologie wird zwar überwiegend für Menschen mit Behinderungen eingesetzt, jedoch besitzt sie ebenfalls einen Nutzen für gesunde Menschen. BCIs lassen sich zur Verbesserung der kognitiven Leistungsfähigkeit [67] und zur Behandlung von psychischen Störungen, wie Epilepsie [164] und Aufmerksamkeitsdefizit [166] einsetzen. Eine weitere Anwendung bietet die Erfassung des kognitiven Zustands von Fahrern. Als Indikatoren zur Feststellung der Aufmerksamkeit dienen Veränderungen im Alpha-Frequenzbereich in den aufgenommenen EEG-Signalen [106]. Auch kommen BCIs bei

Unterhaltungsanwendungen zum Einsatz. Über Bewegungsvorstellungen sind bereits einfache Videospiele bedienbar [92].

## 2.5. Bewertung von BCIs

Die Leistung eines BCIs wird durch eine Vielzahl an Faktoren beeinflusst. Zu diesen Faktoren gehören z.B. das verwendete Paradigma, das Anwendungsprotokoll, die zu erkennenden Gehirnmuster, die Auswahl der Klassifikationsmerkmale, die Art des Klassifikators, die Anwendung und das Feedback für den Nutzer [160]. Für einen Vergleich der verschiedenen BCIs sind daher einheitliche Verfahren und Kriterien zur Bewertung erforderlich.

### 2.5.1. Kreuzvalidierung

Vor dem Einsatz eines Klassifikators empfiehlt sich die Evaluierung seiner Leistung. Die Leistung eines Klassifikators hängt von seiner Generalisierbarkeit ab. Dies bedeutet, dass ein Klassifikator daran gemessen wird, wie gut er Daten klassifiziert, auf die er nicht trainiert wurde. Für eine solche Bewertung kommen Verfahren wie das der Kreuzvalidierung zum Einsatz. Voraussetzung für die Validierung ist ein Datensatz zum Training des Klassifikators mit bekannten Klassenzugehörigkeiten.

Bei der  $k$ -fachen Kreuzvalidierung [89] wird ein Datensatz  $D$  in  $k$  Teilmengen  $D_1, \dots, D_k$  aufgeteilt. Die Aufteilung erfolgt zufällig und die Teilmengen besitzen ungefähr die gleiche Größe. Der Klassifikator wird insgesamt  $k$  mal trainiert und getestet. In jeder Iteration  $i \in \{1, \dots, k\}$  wird die Teilmenge  $D_i$  als Testdatensatz und die verbleibenden  $k - 1$  Teilmengen  $D \setminus D_i$  als Trainingsdatensatz verwendet. Unter Verwendung der  $k$ -fachen stratifizierten Kreuzvalidierung, besitzt jede der  $k$  Teilmengen die gleiche Verteilung an Klassenbezeichnungen wie in dem gesamten Datensatz. Das Ergebnis der Kreuzvalidierung ist eine Zufallszahl, basierend auf der Aufteilung des Datensatzes in Teilmengen. Da eine Validierung aller möglichen Kombinationsmöglichkeiten zu auf-

Tabelle 2.1.: Konfusionsmatrix für einen binären Klassifikator.

		Vorhergesagte Klasse	
		Positiv	Negativ
Tatsächliche Klasse	Positiv	Richtig positiv	Falsch negativ
	Negativ	Falsch positiv	Richtig negativ

wändig ist, empfiehlt sich eine mehrfache Durchführung der k-fachen Kreuzvalidierung. Für reale Daten ist die 10-fache stratifizierte Kreuzvalidierung die beste Methode zur Evaluierung, selbst wenn die Rechenleistung mehr Teilmengen erlaubt.

### 2.5.2. Konfusionsmatrix

Die Konfusionsmatrix [160] (auch als Kontingenztafel bezeichnet) zeigt die Beziehung zwischen den tatsächlichen Klassen (die erwarteten Ausgaben) und den vorhergesagten Klassen (die Ausgaben des Klassifikators). Ein Beispiel für eine Konfusionsmatrix befindet sich in der Tabelle 2.1. Bei einem binären Klassifikator, mit einem aktiven Kontrollzustand (positive Klasse) und einem passiven Nichtkontrollzustand (negative Klasse), stehen die Begriffe *richtig positiv* (engl. True Positive (TP)), *falsch negativ* (engl. False Negative (FN)), *falsch positiv* (engl. False Positive (FP)) und *richtig negativ* (engl. True Negative (TN)) für Treffer, Versäumnis, Fehlaktivierung bzw. korrekte Ablehnung. Für Konfusionsmatrizen mit mehr als zwei Klassen existieren keine speziellen Bezeichnungen für die Felder innerhalb der Matrix. Jedes Element  $n_{ij}$  innerhalb der Konfusionsmatrix beschreibt, wie viele Proben der Klasse  $i$  als Klasse  $j$  vorhergesagt wurden. Die Anzahl an korrekten Klassifikationen wird durch die Diagonalelemente  $n_{ii}$  dargestellt und die Fehlklassifikationen durch die Nichtdiagonalelemente  $n_{ij}$ .

### 2.5.3. Statistische Gütekriterien der Klassifikation

Die Konfusionsmatrix ermöglicht die Bestimmung verschiedener Gütekriterien zur Beurteilung des verwendeten Klassifikators. In der BCI-Forschung sind die Klassifikations-



genauigkeit (engl. Accuracy (ACC)) und die Fehlerrate (engl. Error Rate (ERR)) die am häufigsten verwendeten Evaluationskriterien [160]. Die Genauigkeit, auch als Gesamtgenauigkeit (engl. Overall Accuracy) bezeichnet, wird wie folgt berechnet:

$$ACC = \frac{\sum_{i=1}^M n_{ii}}{\sum_{i=1}^M \sum_{j=1}^M n_{ij}} \quad (2.1)$$

wobei  $M$  für die Anzahl an Klassen steht. Ein Zufallsklassifikator besitzt bereits eine Genauigkeit von  $\frac{100\%}{M}$ . Die Fehlerrate ist definiert als

$$ERR = 1 - ACC. \quad (2.2)$$

Neben der Genauigkeit und der Fehlerrate existieren Maße, die nicht empfindlich auf eine ungleiche Klassenverteilung reagieren. Zu diesen Maßen gehören die Sensitivität (auch als Richtig-positiv-Rate bezeichnet; engl. Sensitivity oder True Positive Rate (TPR)) und die Spezifität (auch als Richtig-negativ-Rate bezeichnet; engl. Specificity oder True Negative Rate (TNR)) [61]. Die Sensitivität beschreibt den Anteil an korrekt klassifizierten positiven Beispielen und entspricht der Wahrscheinlichkeit

$$TPR = \frac{TP}{TP + FN}. \quad (2.3)$$

Hingegen beschreibt die Spezifität den Anteil an korrekt klassifizierten negativen Beispielen und entspricht der Wahrscheinlichkeit

$$TNR = \frac{TN}{TN + FP}. \quad (2.4)$$

Ein weiteres Maß für ungleiche Klassenverhältnisse stellt die ausgewogene Genauigkeit (engl. Balanced Accuracy (BA)) dar [165]. Die BA ist das arithmetische Mittel der beiden Metriken TPR und TNR und berechnet sich wie folgt:

$$BA = \frac{TPR + TNR}{2}. \quad (2.5)$$

Für gleiche Klassenverhältnisse sind die beiden Metriken BA und ACC identisch.


#### 2.5.4. Receiver Operating Characteristics (ROC)-Graphen

ROC-Graphen [47] sind eine nützliche Technik zur Visualisierung und Evaluierung von Klassifikatoren. Ein ROC-Graph ist ein zweidimensionaler Graph, in dem die TPR auf die y-Achse und die Falsch-positiv-Rate (engl. False Positive Rate (FPR)) auf die x-Achse aufgetragen wird. Der Wert FPR beschreibt den Anteil an falsch klassifizierten negativen Beispielen und entspricht der Wahrscheinlichkeit

$$FPR = 1 - TNR. \quad (2.6)$$

Der Graph zeigt somit den relativen Kompromiss zwischen der Leistung (richtig Positive) und den Kosten (falsch Positive) eines Klassifikators.

Liefert ein Klassifikator nur die Klassenbezeichnung, handelt es sich um einen diskreten Klassifikator. Diskrete Klassifikatoren produzieren ein FPR- und TPR-Paar, welches als Punkt in dem ROC-Graphen eingezeichnet wird. In Abbildung 2.4a ist ein ROC-Graph mit vier diskreten Klassifikatoren (*A* bis *D*) zu sehen. Liegt ein Klassifikator auf der eingezeichneten Diagonalen (Klassifikator *A*), so handelt es sich um einen Zufallsklassifikator. Der Punkt  $(0, 1)$  repräsentiert eine perfekte Klassifikation (Klassifikator *B*). Klassifikatoren im unteren rechten Dreieck klassifizieren schlechter als per Zufall (Klassifikator *C*). Durch Negation des Klassifikators lässt sich der Punkt in das obere linke Dreieck verschieben. Der Klassifikator *D* ist die Negation des Klassifikators *C*.



Abbildungung 2.4.: Ein ROC-Graph mit vier diskreten Klassifikatoren (a) und eine ROC-Kurve mit den Schwellwerten für jeden Punkt (b) (nach [47]).

Neben diskreten Klassifikatoren gibt es auch Klassifikatoren, die für jede zu klassifizierende Instanz eine Wahrscheinlichkeit oder eine Bewertung ausgeben. Diese numerischen Werte repräsentieren den Grad, zu dem eine Instanz zu einer bestimmten Klasse gehört. Unter Verwendung eines Schwellwertes lässt sich diese Art von Klassifikator in einen diskreten Klassifikator überführen. Jeder mögliche Schwellwert erzeugt dabei einen unterschiedlichen Punkt im ROC-Graphen. Für Schwellwerte von  $-\infty$  bis  $+\infty$  entsteht eine Kurve im ROC-Graphen. In Abbildung 2.4b ist eine solche „Kurve“ für zwanzig Instanzen bzw. zwanzig Schwellwerte zu sehen. Da nur eine endliche Anzahl an Instanzen vorliegt, ist das Ergebnis eine Schrittfunktion. Wie in dem Graphen zu sehen, üben die Schwellwerte eine Veränderung auf die Leistung des Klassifikators aus.

ROC-Kurven ermöglichen die Visualisierung der Leistung eines Klassifikators. Die Fläche unterhalb der Kurve (engl. Area Under the Curve (AUC)) liefert einen Wert für den Vergleich von Klassifikatoren. Der Wert AUC liegt zwischen 0 und 1, wobei ein Zufallsklassifikator bereits einen Wert von 0,5 besitzt.

### 2.5.5. Informationstransferrate (ITR)

Die ITR stellt, neben den Parametern aus Abschnitt 2.5.3, ein weiteres Maß zur Bewertung der Leistung eines BCIs dar. Sie beschreibt die Anzahl an Information, die pro Zeiteinheit übertragen wird und lässt sich mit folgender Formel berechnen [186]:

$$\begin{aligned} B_t &= \log_2 N + ACC \log_2 ACC + (1 - ACC) \log_2 \left( \frac{1 - ACC}{N - 1} \right) \\ &= \log_2 N + ACC \log_2 ACC + (ERR) \log_2 \left( \frac{ERR}{N - 1} \right). \end{aligned} \quad (2.7)$$

Die Einheit von  $B_t$  ist Bits pro Wiederholung. Der Wert  $ACC$  steht für die Genauigkeit bzw. die Wahrscheinlichkeit für eine korrekte Klassifikation. Die Genauigkeit ist demnach die Anzahl an korrekten Klassifikationen dividiert durch die Gesamtanzahl an Klassifikationen. Der Wert  $ERR$  ist die Fehlerrate oder die Gegenwahrscheinlichkeit der Genauigkeit und  $N$  die Anzahl an möglichen Klassen.

Um die ITR in Bits pro Minute angeben zu können, wird die Zeitspanne  $T$  in Sekunden benötigt, in der die  $C$  Klassifizierungen stattgefunden haben. Somit ergibt sich die folgende modifizierte Berechnung der ITR:

$$B_m = \frac{60}{T} \cdot C \cdot B_t. \quad (2.8)$$

## 2.6. Neurophysiologische Signale für EEG-basierte BCIs

Es existieren zwei verschiedene Arten von BCIs: endogen- und exogenbasierte Systeme. Die endogenen Systeme basieren auf spontaner Gehirnaktivität und können durch Konzentration auf eine spezifische mentale Aufgabe beeinflusst werden. Der Vorteil dieser Systeme besteht darin, dass keine externe Stimulation des Nutzers notwendig ist. Eine hohe Konzentrationsfähigkeit, die willentliche Kontrolle über die Gehirnaktivität und ein langes Training sind die Voraussetzungen für die Verwendung eines endogenen Systems. Ein exogenes System basiert auf evozierter Gehirnaktivität, hervorgerufen

durch die Konzentration auf einen externen Stimulus. Diese Art von System besitzt die Vorteile, dass für ihre Verwendung kein Training notwendig ist und hohe Kommunikationsgeschwindigkeiten erreicht werden können. Außerdem sind diese Systeme für einen großen Nutzerkreis anwendbar [128].

Bei der Auswahl eines Paradigmas müssen, neben dessen Vor- und Nachteilen, auch die Möglichkeiten des Nutzers beachtet werden. So ist z.B. die Verwendung von sensorischen Rhythmen (SMR) für Personen schwierig, die schon seit vielen Jahren oder seit ihrer Geburt gelähmt sind. Für z.B. sehbehinderte Menschen sind die Paradigmen, die eine visuelle Aufmerksamkeit benötigen, unangebracht [38].

Im folgenden Abschnitt wird auf die drei exogenen Paradigmen SSVEP, P300 und Fehlerpotenziale eingegangen. Von den endogenen Paradigmen werden die SMR und Alphawellen erläutert.

### 2.6.1. Steady-State Visual Evoked Potentials (SSVEPs)

Visuell evozierte Potenziale (engl. Visual Evoked Potentials (VEPs)) sind Modulationen der Gehirnaktivität, die im visuellen Kortex auftreten und durch eine visuelle Stimulation hervorgerufen werden [175]. Liegt die Stimulationsfrequenz unter 2 Hz, werden die visuell evozierten Potenziale als transiente VEPs (engl. Transient Visual Evoked Potentials (TVEPs)) bezeichnet. Die transienten Reize erfolgen in so großen Abständen, dass das visuelle System in den Ruhezustand zurückkehren kann. Erfolgt die Stimulation mit Frequenzen ab 6 Hz, wird der neue Reiz bereits ausgelöst, bevor die Antwort auf den vorherigen Reiz abgeklungen ist. Dies führt zu einer Überlagerung der VEPs in dem EEG. Diese Art von VEPs werden als SSVEPs bezeichnet. Eine wichtige Eigenschaft von SSVEPs besteht darin, dass ihre Frequenz in dem EEG exakt der Stimulationsfrequenz entspricht [60]. Im Gegensatz zu TVEPs sind SSVEPs weniger anfällig gegenüber Störquellen, wie z.B. EOG, Augenblinzeln, EMG und der Netzfrequenz [64].

Ein SSVEP-basiertes BCI präsentiert dem Nutzer mehrere Stimuli, die mit verschiedenen konstanten Frequenzen oszillieren. Indem der Nutzer seine Konzentration auf eine

dieser Stimuli richtet, lässt sich dessen Intention, durch eine Analyse der EEG-Signale an einer bestimmten Frequenz oder eines Frequenzbereiches, bestimmen [4]. Wird eine der Stimulationsfrequenzen in den EEG-Signalen detektiert, so wird das der Frequenz zugeordnete Kommando ausgeführt. Diese Kommandos ermöglichen z.B. die Steuerung von externen Geräten oder Computeranwendungen.

Entsprechend der Art, mit der die Aufmerksamkeit auf die Stimulanz gerichtet wird, wird zwischen offener und verdeckter Aufmerksamkeit unterschieden. Bei der offenen Aufmerksamkeit richtet der Mensch seine Augen auf die Stimulanz. Das Ziel wird fokussiert und somit foveal präsentiert. Hingegen beachtet der Mensch bei der verdeckten Aufmerksamkeit die Stimulanz im peripheren Sichtfeld, während der Blick nicht auf das Ziel gerichtet ist [88]. Ein von der Blickrichtung unabhängiges BCI ist für die Anwender notwendig, die über keine willentliche Bewegungsfähigkeit der Augen verfügen.

Zur Stimulation kommen blinkende Elemente, in Form von alternierenden Farben oder invertierenden Schachbrettern, zum Einsatz. Präsentiert werden die Ziele entweder auf einem Monitor oder über Leuchtdioden (engl. Light-Emitting Diodes (LEDs)). Aufgrund der Bildwiederholungsrate des Monitors, ist die Anzahl an möglichen Stimulationsfrequenzen begrenzt. Für ein BCI mit vielen Kommandos ist daher eine Stimulation mit LEDs vorzuziehen. Hierfür ist jedoch eine komplexere Hardware notwendig [182].

Die Amplitude und die Phase einer SSVEP-Antwort basieren auf der Frequenz, der Intensität und der Struktur des sich wiederholenden visuellen Musters [190]. Es ist möglich SSVEP-Antworten in einem Frequenzbereich bis 100 Hz zu erhalten [70]. In der Literatur erfolgt eine Einteilung in drei Frequenzbereiche: niedrig (6-15 Hz), mittel (15-40 Hz) und hoch (40-60 Hz) [60]. Die stärksten Antworten treten für geringe Stimulationsfrequenzen um 15 Hz auf [132].

Geringe Frequenzen erzeugen zwar SSVEP-Antworten mit einer hohen Amplitude, jedoch wirken sie auch ermüdend auf den Nutzer und es besteht die Gefahr, dass sie einen epileptischen Anfall auslösen können [53]. Aus Sicherheitsgründen und zur Erhöhung des Komforts werden daher Stimulationsfrequenzen über 30 Hz bevorzugt. In diesem Bereich




Abbildung 2.5.: a) Amplitudenspektrum eines EEG-Signals bei visueller Stimulation des Probanden mit einer Lichtquelle. Die LED blinkte mit einer Frequenz von 14 Hz. b) Amplitude und Phase für ein SSVEP-BCI mit vier Klassen. Jede der vier LEDs blinkte mit einer Frequenz von 14 Hz, jedoch phasenverschoben.

existieren nur wenige Frequenzen, die eine ausreichend starke SSVEP-Antwort erzeugen. Um die Anzahl an Kommandos zu erhöhen, besteht die Möglichkeit, dieselbe Frequenz für die Stimuli zu verwenden, die jedoch phasenverschoben präsentiert wird. In diesem Fall wird, neben der Amplitude der Stimulationsfrequenz, die Phasendifferenz zwischen der SSVEP-Antwort und einem der Stimulationssignale berechnet [123].

Die Abbildung 2.5a zeigt ein exemplarisches Amplitudenspektrum bei einer Stimulation mit 14 Hz, welches über eine Fouriertransformation berechnet worden ist. Neben der eigentlichen Stimulationsfrequenz ist auch die zweite (28 Hz) und dritte harmonische Frequenz (42 Hz) in dem Spektrum zu sehen. Durch Berücksichtigung der visuell evozierten harmonischen Oszillationen lässt sich die Genauigkeit eines BCIs signifikant verbessern [125]. In der Abbildung 2.5b ist die Amplitude und die Phase eines SSVEP-BCIs mit vier Stimuli zu sehen. Jede der vier Stimuli blinkte mit derselben Frequenz (14 Hz), jedoch phasenverschoben. Bei der Darstellung in Polarkoordinaten entspricht die Amplitude dem Radius und die Phase dem Winkel.




Abbildung 2.6.: P300-Komponente eines ereigniskorrelierten Potenzials (a) und eine mögliche Matrixanordnung zum Evozieren des Potenzials (b).

In vielen Studien wurden bereits SSVEP-basierte BCIs erfolgreich getestet [120, 33, 99, 172, 115, 179, 113]. Der SSVEP-Ansatz ist das derzeit schnellste und zuverlässigste Paradigma im BCI-Bereich. Die Anzahl an Kommandos variiert zwischen 2 [120, 88] und 48 [60]. In [178] wird ein SSVEP-basiertes System mit 5 Stimuli beschrieben, mit dem 7 Probanden eine Klassifikationsgenauigkeit von  $96,79 \pm 7,88 \%$  und eine ITR von  $61,70 \pm 32,68$  bits/min erreicht haben. Ein Proband dieser Studie erzielte in einem Durchlauf eine ITR von 124 bits/min. Auch andere Veröffentlichungen berichten von Genauigkeiten über 90 % [88, 172].

### 2.6.2. P300-Potenziale

Als P300 wird die Komponente eines ereigniskorrelierten Potenzials bezeichnet, die als positiver Peak im EEG, ungefähr 300 ms nach der Präsentation eines Stimulus, erkennbar ist. Das P300-Potenzial tritt im EEG über dem Parietallappen, nach der Präsentation eines sogenannten „oddball“ Stimulus, auf. Dies ist ein seltener aber für den Nutzer bedeutender Stimulus, innerhalb einer Serie von regelmäßig auftretenden Stimuli [171]. Ein evoziertes P300-Potenzial ist in der Abbildung 2.6a zu sehen. Je seltener der Stimulus



auftaucht, umso größer ist die Amplitude des Potenzials [146]. Wird ein P300-basiertes BCI über einen längeren Zeitraum verwendet, besteht die Möglichkeit, dass sich der Nutzer an den unregelmäßigen Stimulus gewöhnt und sich die P300-Amplitude verringert [151].

Eine sehr bekannte BCI-Anwendung ist der P300-Speller. Dieser präsentiert dem Nutzer eine Matrix mit Buchstaben oder anderen Elementen auf einem Monitor. Die Zeilen und Spalten dieser Matrix leuchten in zufälliger Reihenfolge auf, während sich der Anwender auf das gewünschte Element konzentriert und dessen Hervorhebungen in Gedanken zählt. Da nur die Zeile und Spalte, an der sich das Element befindet, ein P300-Potenzial hervorrufen, lässt sich das Zielsymbol durch diesen Effekt bestimmen. Zur Verbesserung der Genauigkeit leuchten die Zeilen und Spalten wiederholt auf und die Signale der entsprechenden Zeilen und Spalten werden über mehrere Durchläufe gemittelt [45]. Eine beispielhafte Matrixanordnung eines P300-Spellers ist in der Abbildung 2.6b zu sehen.

Neben der Anzahl an Wiederholungen besitzen weitere Parameter einen Einfluss auf die Leistung des Nutzers. Mit einem Interstimulus-Intervall (ISI) von 175 ms lässt sich eine höhere Genauigkeit erzielen als mit einem ISI von 350 ms. Als ISI wird der zeitliche Abstand zwischen zwei Stimuli bezeichnet. Weiterhin ist die Genauigkeit für eine  $3 \times 3$  Matrix größer als für eine  $6 \times 6$  Matrix, wobei die ITR für eine  $6 \times 6$  Matrix größer ist als für eine  $3 \times 3$  Matrix [162]. Die Leistung nimmt bei der Verwendung von grün/blau blinkenden Elementen, anstelle von weiß/grau blinkenden Elementen, zu [167]. Eine Abnahme der Leistung tritt bei der Verwendung von Matrizen mit kleinen Symbolen ein [154].

Außer dem zeilen- und spaltenweisen Hervorheben der Matrixelemente, auch als Zeilen/Spalten-Paradigma (engl. Row/Column Paradigm (RCP)) bezeichnet, existieren weitere Verfahren zur Realisierung eines P300-Spellers. Zu diesen zählt das Einzelzeichen-Paradigma (engl. Single-Character Paradigm (SCP)), bei dem die Elemente einzeln aufleuchten [65]. Eine andere Möglichkeit bietet die Hervorhebung von

Regionen [48]. Die besten Ergebnisse erzielt das Schachbrett-Paradigma (engl. Checkerboard Paradigm (CBP)), welches die Symbole virtuell auf einem Schachbrett platziert. Vor jeder Sequenz findet eine Zufallsgenerierung von zwei virtuellen Matrizen statt. Eine Matrix beinhaltet die Symbole auf den weißen Feldern und eine andere Matrix die Symbole der schwarzen Felder. In jeder Sequenz werden die Zeilen und Spalten der beiden virtuellen Matrizen hervorgehoben, anstelle der Zeilen und Spalten der gesamten Matrix. Gegenüber dem herkömmlichen Verfahren besitzt dieses Verfahren den Vorteil, dass die Wahrscheinlichkeit, ein falsches Element aus der direkten Nachbarschaft des Zielelementes auszuwählen, minimiert wird. In einer Studie mit 18 Probanden wurde eine Klassifikationsgenauigkeit von 91,52 % und eine ITR von 22,59 bits/min erzielt [171].

Neben dem evozierten P300-Potenzial hängt die Leistung eines visuellen P300-basierten BCIs auch von dem visuell evozierten Potenzial ab. Die Amplitude eines visuell evozierten Potenzials ist am größten, wenn das Ziel foveal präsentiert wird. Im Gegensatz dazu wird die P300-Antwort nicht davon beeinflusst, ob der Nutzer direkt auf das Ziel blickt. Somit funktioniert diese Art von BCI am besten für Anwender, die über eine Kontrolle der Augenbewegungen verfügen [28].

Anstelle von visuellen Stimuli kommen auch auditive [59] und taktile [26] Stimuli zum Einsatz.

### **2.6.3. Fehlerpotenziale**

Fehlerpotenziale (engl. Error Potentials (ErrPs)) gehören zu den ereigniskorrelierten Potenzialen (engl. Event-Related Potentials (ERPs)). Ein Fehlerpotenzial tritt auf, wenn eine Person selbst einen Fehler realisiert oder sie über eine Rückmeldung auf den Fehler aufmerksam wird. Es wird angenommen, dass Fehlerpotenziale im Frontallappen des Gehirns oder konkret im anterioren cingulären Cortex entstehen [32].

Es existieren vier Arten von Fehlerpotenzialen: Reaktions-Fehlerpotenziale, Feedback-Fehlerpotenziale, Beobachtungs-Fehlerpotenziale und Interaktions-Fehlerpotenziale [51].

Die Reaktions-Fehlerpotenziale treten auf, wenn eine Person schnell hintereinander Entscheidungen treffen muss und dabei eine falsche Entscheidung trifft (z.B. wenn die Person eine Taste mit der linken Hand drückt, obwohl sie die rechte Hand hätte benutzen sollen). Im Signalverlauf sind zwei dominante Ausschläge zu beobachten. In einem Zeitfenster von 0-160 ms nach der inkorrekten Entscheidung taucht ein negatives Potenzial (engl. Error Negativity (Ne)), mit einem fronto-zentralen Maximum, auf. Darauf folgt, in einem Zeitfenster von 200-500 ms nach der fehlerhaften Entscheidung, ein positives Potenzial (engl. Error Positivity (Pe)) mit einem zentro-parietalen Maximum [44].

Wird eine Person über eine visuelle, akustische oder somatosensorische Rückmeldung darüber informiert, ob ihre Reaktion oder Antwort fehlerhaft ist, so treten Feedback-Fehlerpotenziale auf (z.B. im Zuge einer Zeitschätzung). Deren Merkmal ist eine Negativierung im EEG 230-330 ms nach der Rückmeldung über den gemachten Fehler. An den mittleren Elektroden ist die Negativierung größer, im Vergleich zu den lateralen Elektroden. Die Größe der Amplitude unterscheidet sich je nach verwendeter Modalität für die Rückmeldung [121].

Beobachtet eine Person einen Fehler, der durch eine andere Person hervorgerufen wurde, so kommt es zum Auftreten von Beobachtungs-Fehlerpotenzialen (z.B. bei der Beobachtung einer Person, die eine Wahlreaktionsaufgabe absolviert). Im EEG ist eine Negativierung 90 ms nach dem beobachteten Fehler zu sehen, mit einem Maximum nach 252 ms. Die Amplitude ist maximal an den mittleren frontalen Elektroden [174].

Interaktions-Fehlerpotenziale treten als Reaktion auf einen Fehler auf, der bei der Interaktion mit einem technischen System entsteht (z.B. wenn ein BCI eine inkorrekte Klassifikation liefert und somit ein anderes Kommando aussendet, als vom Nutzer beabsichtigt). Ein Interaktions-Fehlerpotenzial besteht aus vier Komponenten, die im fronto-zentralen Bereich des Gehirns auftreten [51]. Ein erster positiver Ausschlag taucht 200 ms nach der Rückmeldung des Systems auf. Darauf folgt ein negativer und ein positiver Ausschlag 270 bzw. 370 ms nach erfolgter Rückmeldung. Zum Schluss ist ein breiter negativer Ausschlag, 470 ms nach der Rückmeldung, zu sehen. Die zeitliche und topogra-




Abbildung 2.7.: Zeitliche und topografische Darstellung eines Interaktions-Fehlerpotenzials. Gezeigt wird die Differenz zwischen den fehlerhaften und den korrekten Wiederholungen. Die Signale links im Bild wurden an der Elektrode  $FC_z$  gemessen. Die Fehlerrate betrug 30 % und die Rückmeldung erfolgte zum Zeitpunkt 0 ms.

fische Darstellung eines Interaktions-Fehlerpotenzials ist in der Abbildung 2.7 zu sehen. Den Diagrammen liegen 60 Wiederholungen von fehlerhaften und 140 Wiederholungen von korrekten Rückmeldungen zugrunde.

Fehlerpotenziale entstehen implizit, ohne, dass der Mensch diese aktiv generieren muss. Systeme, die diese Art von Information nutzen, werden auch als passive BCIs bezeichnet [193]. Die Motivation des Nutzers und die Bedeutung des Fehlers für ihn, besitzen einen Einfluss auf die Modulation der Fehlerpotenziale [66]. Ein zu häufiges Auftreten eines Fehlers führt zu einer Verringerung der Amplitude des Fehlerpotenzials [31].

Eine Anwendungsmöglichkeit von Fehlerpotenzialen besteht in der Verifizierung von Klassifikationsergebnissen eines BCIs. In diesem Fall wird dem Nutzer des Systems das detektierte Kommando vor seiner Ausführung angekündigt. Folgt der Rückmeldung ein Fehlerpotenzial, so wird das Kommando ignoriert [51]. Alternativ kommt das Kommando mit der nächstgrößeren Wahrscheinlichkeit zur Ausführung [36]. Eine weitere Möglichkeit besteht in der Korrektur eines bereits ausgeführten Kommandos. Taucht nach Ausführung des Kommandos ein Fehlerpotenzial auf, wird die Ausführung rückgängig

gemacht [19]. Weiterhin ermöglichen Fehlerpotenziale eine Anpassung der Parameter eines Klassifikators, um zukünftige Fehler zu vermeiden [107]. In einem autonomen System kann der Mensch als Beobachter fungieren. Sobald das System eine fehlerhafte Aktion ausführt, entsteht im Gehirn des Beobachters ein Fehlerpotenzial. Diese Information ermöglicht die Anpassung des Systems und die Verringerung der Wahrscheinlichkeit für das erneute Auftreten des Fehlers [31].

Bei einem BCI mit zwei Bewegungsvorstellungen ließ sich, unter Verwendung von Fehlerpotenzialen, die Fehlerrate von ca. 30 auf 7 % verringern, was zu einer Verdreifachung der ITR geführt hat. Die Erkennungsrate von korrekten und fehlerhaften Wiederholungen (engl. Trials) betrug 84,7 bzw. 78,8 % [52]. In einer weiteren Studie wurde die Kommunikationsgeschwindigkeit eines P300-Spellers um 49 % gesteigert. Die Genauigkeit der Erkennung von Fehlerpotenzialen betrug 89,1 % [159].

### 2.6.4. Sensomotorische Rhythmen (SMR)

SMR entstehen im sensomotorischen Kortex und umfassen die  $\mu$ - und  $\beta$ -Rhythmen [96]. Die Generierung der Oszillationen im  $\mu$ -Frequenzbereich (8-14 Hz) erfolgt im somatosensorischen Bereich des Gehirns und die Oszillationen im  $\beta$ -Frequenzbereich (15-30 Hz) im motorischen Bereich. Hierdurch sind die  $\mu$ -Rhythmen der Verarbeitung sensorischer Informationen und die  $\beta$ -Rhythmen der motorischen Steuerung zuzuordnen [85].  $\gamma$ -Oszillationen (36-40 Hz) besitzen ebenfalls einen Bezug zu motorischen Aufgaben, sind jedoch selten im EEG von Menschen zu finden [141].

Durch eine sensorische Stimulation, ein motorisches Verhalten oder eine mentale Vorstellung kann es zu einer Unterdrückung oder Verstärkung der Amplituden der  $\mu$ - und  $\beta$ -Rhythmen kommen. Während einer Bewegungsdurchführung oder -vorstellung kommt es zu einer Desynchronisation (engl. Event-Related Desynchronization (ERD)) der beiden Rhythmen. Nach der durchgeführten oder vorgestellten Bewegung erfolgt eine Synchronisation (engl. Event-Related Synchronization (ERS)) der Signale in den beiden Frequenzbereichen [141]. ERD und ERS sind definiert als der prozentuale Leistungsabfall




Abbildung 2.8.: Amplitudenspektrum (a), Signalleistung (b) und ERD/ERS-Verläufe (c) während der Bewegungsvorstellung der linken Hand.

bzw. -anstieg in einem Frequenzband nach einem Ereignis, in Relation zu einem Referenzintervall vor dem Ereignis. Für die ERD/ERS-Berechnung sind mehrere Wiederholungen (engl. Trials) einer Bewegungsvorstellung notwendig. Zuerst findet eine Bandpassfilterung aller Trials, in einem der beiden Frequenzbereiche, statt. Anschließend werden die Amplituden zu jedem Zeitpunkt quadriert, um die Leistung für jeden Datenpunkt zu erhalten. Danach wird über die Trials gemittelt. Zum Schluss erfolgt eine Mittelung der Datenpunkte über die Zeit, um eine Glättung der Daten zu erzielen [136]. Die Abbildung 2.8a zeigt die Abnahme der Amplitude innerhalb des  $\mu$ - und  $\beta$ -Frequenzbereiches während der Bewegungsvorstellung der linken Hand. Der entsprechende Leistungsverlauf und die ERD/ERS-Verläufe sind den Abbildungen 2.8b und 2.8c zu entnehmen.

Den Verläufen liegen 40 Wiederholungen zugrunde. Die Messung erfolgte über dem Kanal  $C_4$ . Nach Beginn der Bewegungsvorstellung, zum Zeitpunkt 0 s, ist ein Abnahme der Signalleistung zu erkennen. Die Bewegungsvorstellung endet zum Zeitpunkt 4 s, was einen Anstieg der Signalleistung zur Folge hat.

Eine Bewegungsvorstellung (engl. Motor Imagery (MI)) ist die mentale Simulation einer motorischen Aktion ohne die Aktivierung der Muskulatur [84]. Die kortikalen Aktivierungsmuster bei einer Bewegungsvorstellung sind ähnlich zu denen bei der Bewegungsausführung [83]. Der Aktivierungsgrad der Hirnareale ist dabei von unterschiedlichen Einflussfaktoren abhängig. Zu diesen Faktoren zählen der Vorstellungsinhalt (einfache oder komplexe Bewegung) [97], die Vorstellungsmodalität (kinästhetische oder visuelle Bewegungsvorstellung) [127] und die Vorstellungsfähigkeit des Menschen. Bei einer kinästhetischen Bewegungsvorstellung stellt sich der Mensch vor, wie sich die Bewegung anfühlt. Hingegen stellt sich der Mensch bei einer visuellen Bewegungsvorstellung vor, wie er seine oder fremde Extremitäten bei einer Bewegung beobachtet. Eine kinästhetische Bewegungsvorstellung lässt sich besser detektieren als eine visuelle Bewegungsvorstellung [127].

Im Gegensatz zu ereigniskorrelierten Potenzialen besitzen Bewegungsvorstellungen keine feste Phasenbeziehung zu dem Ereignis (engl. Non-Phase-Locked). Es tritt zwar eine zeitlich feste Amplitudenveränderung auf, jedoch variiert die Phasenlage dieser Veränderung [135].

Je nach Art der Bewegungsvorstellung treten die ERD/ERS-Muster in unterschiedlichen Gehirnarealen auf. Eine Bewegungsvorstellung der beiden Füße lässt sich über der zentralen Region des motorischen Kortex ableiten (Elektrode  $C_z$ ), eine Bewegungsvorstellung der linken Hand über dem motorischen Kortex der rechten Gehirnhälfte (Elektrode  $C_4$ ) und die Bewegungsvorstellung der rechten Hand über dem motorischen Kortex der linken Gehirnhälfte (Elektrode  $C_3$ ) [86]. Eine topografische Darstellung der Differenz (gemessen als  $r^2$ ), zwischen der Ruhephase und einer Bewegungsvorstellung, befindet sich in Abbildung 2.9. Anhand dieser Darstellung wird ersichtlich, welche Elek-




Abbildung 2.9.: Topografische Darstellung der Differenz (gemessen als  $r^2$ ) zwischen der Ruhephase und einer Bewegungsvorstellung.

trodenpositionen relevant zur Detektion einer Bewegungsvorstellung an einer bestimmten Frequenz sind. Rote Bereiche stehen für relevante Elektrodenpositionen, wohingegen blaue Bereiche nur eine geringe Menge an Informationen liefern.

Eine Vielzahl der nicht-invasiven BCIs basieren auf der Verwendung von SMR, da Menschen in der Lage sind, willentlich Modulationen in den SMR zu generieren [189, 137, 24].

Ein ERD/ERS-BCI setzt für seine Verwendung eine Trainingsphase voraus. Dieses Training fordert den Nutzer auf, eine bestimmte Bewegungsvorstellung durchzuführen. Die dabei auftretenden SMR werden extrahiert und klassifiziert. Während der Trainingsphase erhält der Anwender eine kontinuierliche Rückmeldung, um seine Fähigkeit der Bewegungsvorstellung zu verbessern [98]. Die Rückmeldung über eine erfolgreiche oder erfolglose Bewegungsvorstellung kann visuell oder auditiv erfolgen [129]. Eine effektivere Form des Trainings ermöglicht die Visualisierung der kortikalen Aktivität in Echtzeit [75].

Die ITR eines ERD/ERS-BCIs liegt unterhalb von exogenen Systemen, wie z.B. ein SSVEP-BCI. In [21] wurde mit einem ERD/ERS-BCI, das zwei Bewegungsvorstellungen nutzt, eine maximale ITR von 37,1 bits/min erreicht. Im Vergleich dazu erzielen SSVEP-BCIs eine ITR von über 100 bits/min [180].



### 2.6.5. Alphawellen und Augenartefakte

Alphawellen sind über dem okzipitalen Bereich des Gehirns zu beobachten. Sie liegen in einem Frequenzbereich von 8 bis 12 Hz. Ein Anstieg ihrer Amplituden tritt auf, wenn eine Person wach und entspannt ist und die Augen geschlossen hält. Sobald die Augen geöffnet werden und eine mentale Anstrengung stattfindet, tritt eine Abschwächung der Amplituden auf [62].

Alphawellen wurden bereits erfolgreich zur Steuerung einer Fernbedienung eingesetzt. Die Genauigkeiten lagen zwischen 71 und 96 % [134]. Ebenfalls lassen sich Alphawellen zum Ein- und Ausschalten eines Media-Players einsetzen [184]. Liegen die Stimulationsfrequenzen bei einem SSVEP-basierten BCI im Alpha-Frequenzband, so kann es zu Fehlklassifikationen kommen, wenn die Person entspannt. Die Detektion von Alphawellen führte in einem Experiment zu einer Verbesserung der Genauigkeit von 90 auf 97 % [181].

In der Abbildung 2.10 ist ein Zeit-Frequenz-Diagramm für den Kanal  $O_z$  zu sehen. Dem Diagramm liegen 50 Wiederholungen zugrunde, in denen der Proband seine Augen schließt und geschlossen hält. Zum Zeitpunkt 0 ms erhielt der Proband die Instruktion, seine Augen zu schließen. Nach ca. 500 ms treten Alphawellen im Frequenzbereich von 8 bis 12 Hz auf. Vorher ist eine erhöhte Aktivität unter 8 Hz zu beobachten. Diese resultiert aus dem Artefakt, das beim Schließen der Augen entsteht. Der Einfluss des Artefaktes auf das Alpha-Frequenzband ist vernachlässigbar. Neben der Detektion von Alphawellen lässt sich das Schließen der Augen auch über die Detektion des auftretenden Artefakts feststellen.

Artefakte sind unerwünschte Signale nicht zerebralen Ursprungs, die die zu messende Gehirnaktivität kontaminieren und somit zu einer Reduzierung der Leistung eines BCIs führen. Es wird zwischen physiologischen Artefakten und nicht-physiologischen oder technischen Artefakten unterschieden. Technische Artefakte treten überwiegend aufgrund von Netzrauschen oder Veränderungen in den Impedanzen der Elektroden




Abbildung 2.10.: Zeit-Frequenz-Diagramm für den Kanal  $O_z$ . Zum Zeitpunkt 0 ms erhielt der Proband die Instruktion, seine Augen zu schließen. Nach ca. 500 ms tritt eine erhöhte Aktivität im Alpha-Frequenzband auf.

auf. Über eine Filterung oder Abschirmung lässt sich diese Art von Artefakten vermeiden. Physiologische Artefakte entstehen aufgrund von Muskel-, Augen- und Herzaktivität. Diese Artefakte werden auch als EMG-, EOG- und Elektrokardiographie (EKG)-Artefakte bezeichnet [46].

Bevor es zu einer Generierung von Alphawellen kommen kann, muss der Mensch seine Augen schließen. Das dabei auftretende Artefakt gehört zu den EOG-Artefakten. EOG-Artefakte entstehen durch Blinzeln oder Augenbewegungen.

Ein Mechanismus, der Artefakte bei Augenbewegungen erzeugt, ist die Hornhaut-Netzhaut-Dipolbewegung. Das Auge bildet einen elektrischen Dipol, da die Hornhaut positiv und die Netzhaut negativ geladen sind. Sobald sich das Auge bewegt, bewegt sich auch der Dipol. Dies bewirkt eine Veränderung des elektrischen Feldes um das Auge, was wiederum das elektrische Feld über der Kopfhaut beeinflusst, das über neuronale Potenziale erzeugt wird. Die Netzhaut-Dipolbewegung ist ein ähnlicher Mechanismus,




Abbildung 2.11.: Signalverläufe am Kanal  $FC_z$  für verschiedene Augenartefakte. Zum Zeitpunkt 0 s erhielt der Proband die Instruktion, seine Augen zu schließen oder zu öffnen, zu blinzeln oder die Augen offen zu halten.

der Artefakte bei Augenbewegungen erzeugt. Der Dipol entsteht hier jedoch aufgrund von Potenzialunterschieden über der Netzhaut [37].

Beim Blinzeln entstehen Artefakte aufgrund der Bewegung des Augenlids. Das elektrische Feld um die Augen wird durch die Bewegung des Augenlids über die Hornhaut des Auges beeinflusst, selbst, wenn keine Rotation des Augapfels stattfindet [117]. Die Augenlider fungieren dabei als „gleitende Elektroden“, die die positiven Ladungen der Hornhaut zu den fronto-polaren Elektroden kurzschließen [80].

Die Abbildung 2.11 zeigt die Signalverläufe verschiedener Augenartefakte am Kanal  $FC_z$ . Den Signalverläufen liegen 50 Wiederholungen zugrunde. Zum Zeitpunkt 0 s erhielt der Proband die Instruktion, seine Augen zu schließen oder zu öffnen, zu blinzeln oder die Augen offen zu halten und somit kein Artefakt zu erzeugen. Im EEG zeigt sich das Blinzeln als ein positiver Ausschlag mit einer Dauer von wenigen Zehntelsekunden. Beim Schließen der Augen steigt das Signal zuerst stark an und fällt anschließend langsam ab. Der Signalverlauf beim Öffnen der Augen ist invertiert zum Signalverlauf beim Schließen der Augen. Hauptsächlich sind die Signale in der fronto-polaren Region sicht-

bar. Diese propagieren jedoch zu allen anderen Elektroden und werden mit zunehmender Distanz von der fronto-polaren Region schwächer. Aufgrund der hohen Amplituden von ca.  $60 \mu V$ , ist der Einfluss von Augenartefakten auf eine Analyse im Zeitbereich sehr groß.

In BCIs ist das Auftreten von Artefakten unerwünscht. Eine Möglichkeit im Umgang mit Artefakten besteht darin, den Anwender des Systems anzuweisen, ein Blinzeln oder Körperbewegungen zu vermeiden. Außerdem besteht die Möglichkeit, kontaminierte Signale manuell oder automatisch zu detektieren und zu verwerfen. Weiterhin lassen sich Artefakte identifizieren und entfernen, wobei alle anderen Signalkomponenten erhalten bleiben [46].

Anstelle einer Vermeidung, Verwerfung oder Entfernung von Artefakten, können Systeme Artefakte aufnehmen und verarbeiten, um behinderten oder gesunden Menschen eine Kommunikationsmöglichkeit zu bieten. Bei dieser Art von Systemen handelt es sich jedoch nicht um ein BCI, da die Kommunikation abhängig von der Muskelaktivität ist. Die Zuverlässigkeit dieser Systeme ist größer als die von BCIs. Behinderte Menschen, die keine willentlichen Bewegungen ausführen können, sind jedoch nicht in der Lage, diese Art von System zu verwenden [128].

Artefakte im EEG, hervorgerufen durch Blinzeln, wurden bereits erfolgreich als Steuersignale für eine virtuelle Tastatur verwendet [30]. Auch lässt sich über die Artefakte im EEG die Müdigkeit eines Menschen analysieren [148]. Zur Detektion von Blinzeln oder Augenbewegungen wird eher die EOG verwendet als die EEG. So wurde bereits die EOG zur Steuerung von Geräten, wie einem Computer [76] oder einem Rollstuhl [14], verwendet. Andere Anwendungen sind die Detektion von Müdigkeit [34] und die Berechnung der Blickrichtung [191].

## Kapitel 3.

### Swift Brain-Computer Interface (sBCI)-System

Dieses Kapitel stellt das hybride BCI-System vor, welches im Rahmen des abgeschlossenen Forschungsprojektes „Schnelle Brain-Computer Interface (BCI)-Systeme für Alltagsanwendungen“ entwickelt wurde. In dem Projekt wurde der sBCI-Helm entwickelt, der sowohl über Elektroden zur Aufnahme von EEG-Signalen verfügt als auch über einen visuellen Stimulator im Sichtfeld des Nutzers. Neben den Hardwarekomponenten verfügt das System über eine Signalverarbeitung zur Erkennung von Bewegungsvorstellungen und SSVEPs. Mit dem System können Menschen Haushaltsgeräte über eine grafische Benutzeroberfläche steuern. Erste experimentelle Ergebnisse und eine ausführliche Beschreibung des Systems sind der Arbeit [113] und der Dissertation [111] zu entnehmen.

Aufgrund der Position der visuellen Stimulation im peripheren Sichtfeld des Nutzers, eignet sich der sBCI-Helm optimal zur Steuerung eines Roboterarmes. Der Nutzer ist somit in der Lage Kommandos an den Roboter zu senden, während er diesen stets im Blick hat. Daher wurde der sBCI-Helm für die Experimente dieser Dissertation gewählt.

Zu Beginn dieses Kapitels erfolgt eine Vorstellung der Hardwarekomponenten des Systems. Anschließend folgt eine Beschreibung der bereits implementierten Algorithmen. Zum Schluss wird die Studie, in der das System getestet wurde, präsentiert. Die Probanden dieser Studie hatten zur Aufgabe, Haushaltsgeräte über eine grafische Benutzeroberfläche zu bedienen. Zur Auswahl der Geräte dienten Bewegungsvorstellungen, die die Probanden in einem ersten Schritt trainieren mussten. Für die Steuerung eines aus-





Abbildung 3.1.: sBCI-Helm bestehend aus einem Hartschalenhelm mit 22 EEG-Elektroden, vier SMD-LEDs zur visuellen Stimulation für ein SSVEP-BCI, einer Kamera zur Umgebungsbeobachtung (a), zwei Augenkameras, zwei IR-LEDs und zwei dichroitischen Spiegeln zur Aufnahme der Augen (b).

gewählten Gerätes nutzten die Probanden ein SSVEP-BCI. Die Ergebnisse dieser Studie geben Aufschluss über die Genauigkeiten und die Informationstransferraten, die die Nutzer des Systems erreichen können. Diese Parameter ermöglichen eine Entscheidung, ob sich das System zur Steuerung eines Roboterarmes eignet und, ob Verbesserungen in den Signalverarbeitungen notwendig sind.

### 3.1. Hardware

Das sBCI-System, zu sehen in der Abbildung 3.1, beinhaltet auf der Hardware-Seite einen leichtgewichtigen und ergonomischen Hartschalenhelm. Dieser besteht aus 22 Elektroden zur EEG-Messung, zwei Augenkameras, zwei dichroitischen Spiegeln zur Spiegelung der Augen für die Augenkameras, zwei Infrarot (IR)-LEDs zur Beleuchtung der Augen, einer Umgebungs-kamera und einem integrierten visuellen Stimulator, der über vier Surface Mounted Device (SMD)-LEDs für ein SSVEP-BCI mit vier Kommandos verfügt. Die



(a) Elektrodenanordnung

(b) Elektrodenhalterung

Abbildung 3.2.: a) Der sBCI-Helm verfügt über 22 Elektroden zur Signalaufnahme. Die 14 grün eingezeichneten Elektroden lassen sich für ein ERD/ERS-BCI verwenden und die 8 blau eingezeichneten Elektroden ermöglichen die Verwendung eines SSVEP-BCIs. Beide Paradigmen nutzen die Elektrode  $P_z$ . Die Elektrode  $AF_z$  ist die Ground-Elektrode. b) Die Elektroden sind mit spiralförmigen Federn verbunden, die sich in die Schale des Helmes einklicken lassen.

vier LEDs besitzen jeweils eine Größe von  $2,0 \times 1,25$  mm und befinden sich an den Ecken der dichroitischen Spiegel. Über diese Anordnung hat der Nutzer die LEDs stets im Blick, wodurch keine Kopf- oder Augenbewegungen erforderlich sind. Um dem Nutzer eine einfache Steuerung mit den vier LEDs zu ermöglichen, leuchten die oberen beiden LEDs rot und die beiden unteren LEDs grün. Die Distanz zwischen einer LED und den Augen des Nutzers beträgt ca. 3 cm. Zurzeit dieser Dissertation lag der Helm in drei Größen vor, die einem Kopfumfang von 56, 58 und 60 cm entsprachen.

Die EEG-Elektroden befinden sich an vordefinierten Positionen entsprechend des erweiterten internationalen 10-20 Systems zur EEG-Messung. Aufgrund der Abdeckung des motorischen und des visuellen Kortexes, eignet sich der Helm für ein ERD/ERS-BCI und für ein SSVEP-BCI (siehe Abbildung 3.2a). Bei den im Helm integrierten Elektro-

den handelt es sich um kommerziell erhältliche passive Ag/AgCl Gel-Elektroden. Um eine gute Anpassung des Helmes an die Köpfe der Nutzer zu ermöglichen, sind die Elektroden über spiralförmige Federn mit dem Helm verbunden. Dadurch ist es auch möglich Gel zu injizieren und die Kopfhaut aufzurauen, um die Impedanz zu verringern. Eine Detailansicht der verwendeten Elektrodenhalterung ist in der Abbildung 3.2b zu sehen.

Zur Aufnahme der Hirnaktivität wird der Messverstärker Porti 7 (Twente Medical Systems International, Oldenzaal, Niederlande) verwendet. Die Messelektroden sind über die unipolaren Eingänge mit dem Verstärker verbunden. Alle Signale an den unipolaren Eingängen werden gegen ein Referenzsignal verstärkt. Das Referenzsignal ergibt sich aus dem Mittelwert aller angeschlossenen Elektroden. Zur Erdung wird die Elektrode  $AF_z$  mit dem Ground-Anschluss des Verstärkers verbunden. Zusätzlich verfügt der Verstärker über einen Digitaleingang. Der Verstärker ist mit der True Active Shielding (TAS)-Technologie ausgestattet, um Störeinflüsse, wie z.B. Kabelbewegungsartefakte und Netzstörungen (50/60 Hz), auf ein Minimum zu reduzieren. Er verwendet einen Tiefpassfilter erster Ordnung mit einer Grenzfrequenz von 0,27 mal der Abtastfrequenz vor der Analog-Digital-Konvertierung. Die maximale Abtastfrequenz beträgt 2048 Hz. Die Verbindung mit dem PC erfolgt über ein bi-direktionales Glasfaserkabel und ein Glasfaser auf USB-Adapter. Eine kabellose Verbindung ist über Bluetooth möglich.

Die Frequenz und Helligkeit der LEDs wird über einen LED-Mustergenerator geregelt. Dieses Gerät verwendet einen PIC18F4550 Mikrocontroller (Microchip, Chandler, AZ, USA) als Kommunikationsschnittstelle und Taktgeber sowie acht PIC16F690 Mikrocontroller zur unabhängigen Regelung der Helligkeit für acht Ausgangskanäle. Zusätzlich zu den acht Ausgangskanälen verfügt das Gerät über einen Trigger-Ausgang, der das Muster eines Kanales ausgibt. Der Trigger-Ausgang lässt sich mit dem Digitaleingang des Verstärkers Porti 7 verbinden, um das Blinkmuster einer LED als Referenzsignal für ein phasenbasiertes SSVEP-BCI verwenden zu können. Der Generator ermöglicht die Einstellung der Helligkeit, des auszugebenden Musters und der Schiebefrequenz. Alle Para-



meter sind zur Laufzeit softwaremäßig von einem Computer über eine USB-Verbindung einstellbar.

## 3.2. Software

Die Signalaufnahme und -verarbeitung des hybriden sBCI-Systems erfolgt mit dem BCI2000-Framework [156]. Ein mit dem BCI2000-Framework entwickeltes System besteht aus den folgenden vier Modulen: Operator, Signalaufnahme, Signalverarbeitung und Anwendung.

Der Operator dient als zentrales Relais zur Systemkonfiguration und zur Präsentation von Ergebnissen.

Das Signalaufnahmemodul akquiriert die EEG-Signale vom EEG-Verstärker und filtert diese anschließend. Zur Reduzierung von Signalversätzen wird ein Hochpassfilter mit einer Grenzfrequenz von 0,1 Hz verwendet. Das Netzrauschen wird mit einem 50 Hz Kerbfilter reduziert. Der Verstärker arbeitet mit einer Abtastfrequenz von 256 Hz und die Signalaufnahme erfolgt in Blöcken von 32 Datenpunkten. Alle 125 ms sendet somit das Modul neue Datenpunkte an die Signalverarbeitung.

Sobald neue Daten beim Signalverarbeitungsmodul ankommen, speichert dieses die gelieferten Daten in einem zwei Sekunden umfassenden First In - First Out (FIFO)-Puffer. Anschließend erfolgt die Verarbeitung des Puffers mittels der Matlab-Schnittstelle des BCI2000-Frameworks. Die beiden nachfolgenden Abschnitte befassen sich ausführlich mit der Signalverarbeitung der beiden BCI-Paradigmen SSVEP und ERD/ERS. Aufgrund der kontinuierlichen Verarbeitung der Signale und der Einführung eines Nichtkontrollzustandes, operiert das System asynchron. Der Nutzer ist somit in der Lage, zu selbst bestimmten Zeitpunkten ein Kontrollkommando zu senden. Nach einer Klassifikation findet in den nachfolgenden zwei Sekunden keine weitere Klassifikation statt. Hierdurch erhält der Anwender die Gelegenheit, seine Konzentration von einer LED ab-

zuwenden oder eine Bewegungsvorstellung zu beenden. Ansonsten könnte es passieren, dass ein Kommando ungewollt mehrfach hintereinander detektiert wird.

Die Signalverarbeitung übermittelt die Klassifikationsergebnisse an das Anwendungsmodul, welches die Ergebnisse lediglich an eine externe Anwendung weiterleitet. Die Kommunikation zwischen BCI2000 und der externen Anwendung erfolgt über das User Datagram Protocol (UDP)-Netzwerkprotokoll in Echtzeit. Die externe Anwendung ermöglicht die Steuerung von Haushaltsgeräten über eine grafische Benutzerschnittstelle. Sie verarbeitet die empfangenen Klassifikationen und sendet, über eine Infrarotschnittstelle, Steuerkommandos an die Geräte.

### 3.2.1. SSVEP-BCI

Die SSVEP-Signalverarbeitung, zur Detektion der Stimulationsfrequenz, erfolgt mit der Minimum-Energy-Combination (MEC)-Methode. Diese Methode wurde erstmals in [57] beschrieben, mit anderen Methoden verglichen und als beste Methode bewertet. Eine zuverlässige Frequenzdetektion ist mit dem Verfahren schon ab einer Fensterlänge von 750 ms möglich [180]. Im sBCI-Projekt [113] wurde die MEC-Methode verwendet und unter Verwendung des LED-Stimulators getestet. Dieser Abschnitt beschreibt die SSVEP-Signalverarbeitung, die im sBCI-Projekt verwendet wurde. Der gleiche Algorithmus wird zum Testen des sBCI-Systems in dieser Dissertation verwendet.

#### 3.2.1.1. SSVEP-Modell

Zur Berechnung einer SSVEP-Antwort, auf eine visuelle Stimulation mit einer Blinkfrequenz von  $f$  Hz, wird das folgende Modell verwendet [57]:

$$y_i(t) = \sum_{k=1}^{N_h} a_{i,k} \sin(2\pi k f t + \phi_{i,k}) + \sum_j b_{i,j} z_j(t) + e_i(t). \quad (3.1)$$

Dieses Modell ist linear und beschreibt die Zusammensetzung des Signals  $y_i(t)$  zum Zeitpunkt  $t$ . Das Signal  $y_i(t)$  ist die gemessene Spannung zwischen einer Referenzelektrode

und der Elektrode  $i$ . Es besteht aus drei Bestandteilen. Der erste Teil beschreibt die evozierte SSVEP-Antwort, bestehend aus einer Reihe von Sinus-Signalen. Die Frequenzen dieser Signale entsprechen der Stimulationsfrequenz  $f$  mit  $N_h$  Harmonischen. Jedes Sinus-Signal besitzt eine spezifische Amplitude  $a_{i,k}$  und Phase  $\phi_{i,k}$ . Der zweite Teil des Modells beinhaltet die Störsignale  $z_j(t)$ . Diese Störsignale können z.B. durch im Hintergrund ablaufende Gehirnprozesse oder externe Störungen, wie Atmungsartefakte und Interferenzen durch die Stromleitung, hervorgerufen werden. Über die Gewichtungsfaktoren  $b_{i,j}$  wird der Einfluss der Störsignale auf das Elektrodensignal beschrieben. Elektrodenspezifisches Messrauschen wird über die dritte Komponente  $e_i(t)$  definiert.

Liegt von dem Signal ein Zeitsegment mit  $N_t$  Datenpunkten vor, die mit einer Abtastfrequenz  $F_s$  aufgenommen wurden, so lässt sich das Modell in Vektorform darstellen:

$$\mathbf{y}_i = \mathbf{X}\mathbf{a}_i + \mathbf{Z}\mathbf{b}_i + \mathbf{e}_i. \quad (3.2)$$

Der Vektor  $\mathbf{y}_i = [y_i(t), \dots, y_i(N_t)]^T \in \mathbb{R}^{N_t \times 1}$  enthält das EEG-Signal der Elektrode  $i$  aus dem zu analysierenden Zeitintervall und der Vektor  $\mathbf{e}_i \in \mathbb{R}^{N_t \times 1}$  beinhaltet das Messrauschen der Elektrode  $i$ . Die SSVEP-Modellmatrix  $\mathbf{X} \in \mathbb{R}^{N_t \times 2N_h}$  ist wie folgt aufgebaut:

$$\mathbf{X} = [\mathbf{X}_1 \dots \mathbf{X}_{N_h}] \quad (3.3)$$

wobei jede Untermatrix  $\mathbf{X}_k \in \mathbb{R}^{N_t \times 2}$  eine Sinus- und Kosinuskomponente mit der harmonischen Frequenz  $kf$  als Spaltenvektor besitzt. Die zu der Modellmatrix gehörenden Amplituden sind in dem Vektor  $\mathbf{a}_i \in \mathbb{R}^{2N_h \times 1}$  zusammengefasst. In der Matrix  $\mathbf{Z}$  befinden sich in den Spalten die Störsignale und  $\mathbf{b}_i$  ist der dazugehörige Gewichtungsvektor. Es wird dabei angenommen, dass das Zeitsegment kurz genug ist, so dass das Rauschen stationär in diesem Segment bleibt.

Unter der Annahme, dass Signale von mehreren Elektroden  $i = 1, \dots, N_y$  vorliegen, lässt sich das Modell weiter verallgemeinern zu:

$$\mathbf{Y} = \mathbf{XA} + \mathbf{ZB} + \mathbf{E}. \quad (3.4)$$

Die Matrix  $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_{N_y}] \in \mathbb{R}^{N_t \times N_y}$  beinhaltet die Signale der Elektroden als Spaltenvektoren. In der Matrix  $\mathbf{E}$  befindet sich in den Spalten das Messrauschen der Elektroden. Die Matrix  $\mathbf{A} \in \mathbb{R}^{2N_h \times N_y}$  enthält die Amplituden für die Modellmatrix  $\mathbf{X}$  und die Matrix  $\mathbf{B}$  die Skalierungsfaktoren der Störsignalmatrix  $\mathbf{Z}$ .

### 3.2.1.2. Signalvorverarbeitung

Im Rahmen der räumlichen Filterung findet eine Verstärkung der SSVEP-Antworten und eine Verringerung der Stör- und Rauschsignalanteile statt. Eine solche Filterung wird durch eine lineare Kombination, der durch die Elektroden gemessenen Signale, erreicht. Die Kombination der in der Matrix  $\mathbf{Y}$  befindlichen Messsignale erfolgt unter Verwendung des Gewichtungsvektors  $\mathbf{w} \in \mathbb{R}^{N_y \times 1}$ :

$$\mathbf{s} = \sum_{i=1}^{N_y} w_i \mathbf{y}_i = \mathbf{Yw}. \quad (3.5)$$

Das Ergebnis dieser Filterung ist ein einziger Kanal. Da es mehrere Kombinationsmöglichkeiten für die Elektrodensignale gibt, ermöglicht dies die Bildung verschiedener gefilterter Kanäle:

$$\mathbf{S} = \mathbf{YW}. \quad (3.6)$$

Die Gewichte für die  $N_s$  verschiedenen Kombinationen, befinden sich als Spaltenvektoren in der Matrix  $\mathbf{W} \in \mathbb{R}^{N_y \times N_s}$ .

Zur Bestimmung der Gewichtungsmatrix wird die MEC-Methode [57] verwendet, welche sich bereits in vielen Anwendungen [56, 178, 113] bewährt hat. Gegenüber der Bipolaren [49] und der Laplaceschen [71] Kombination, besitzt die Methode den Vorteil,

dass im Vorfeld keine Paare oder Gruppen von Elektroden ausgewählt werden müssen. Sie bildet aus einer beliebigen Anzahl an Elektroden verschiedene gefilterte Signale, in denen die Störsignale so gering wie möglich vorhanden sind.

Um dieses Ziel zu erreichen, erfolgt in einem ersten Schritt die Entfernung der möglichen SSVEP-Antworten aus den aufgenommenen Signalen. Hierfür werden die Elektrosignale auf das orthogonale Komplement der Modellmatrix  $\mathbf{X}$  projiziert:

$$\tilde{\mathbf{Y}} = \mathbf{Y} - \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (3.7)$$

Die Matrix  $\tilde{\mathbf{Y}} \approx \mathbf{Z}\mathbf{B} + \mathbf{E}$  enthält annähernd nur noch die Stör- und Rauschsignale.

Im nächsten Schritt wird nach dem Gewichtungsvektor  $\hat{\mathbf{w}}$  gesucht, der die Energie in den ermittelten Signalen  $\tilde{\mathbf{Y}}$  minimiert. Somit liegt folgendes Optimierungsproblem vor:

$$\min_{\hat{\mathbf{w}}} \|\tilde{\mathbf{Y}} \hat{\mathbf{w}}\|^2 = \min_{\hat{\mathbf{w}}} \hat{\mathbf{w}}^T \tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}} \hat{\mathbf{w}}. \quad (3.8)$$

Die Lösung dieses Minimierungsproblems ist der Eigenvektor  $\mathbf{v}_1$  mit dem kleinsten Eigenwert  $\lambda_1$  der symmetrischen Matrix  $\tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}$ . Dieser Eigenvektor ist der Gewichtungsvektor für einen Kanal. Aufgrund der Symmetrie der Matrix sind alle seine Eigenvektoren orthogonal zueinander. Hierdurch lassen sich weitere Eigenvektoren zur Bildung zusätzlicher unkorrelierter Kanäle verwenden. Basierend auf den aufsteigend sortierten Eigenwerten  $(\lambda_1, \dots, \lambda_{N_y})$  und den dazugehörigen Eigenvektoren  $(\mathbf{v}_1, \dots, \mathbf{v}_{N_y})$ , wird die Gewichtungsmatrix wie folgt bestimmt:

$$\mathbf{W} = \begin{pmatrix} \frac{\mathbf{v}_1}{\sqrt{\lambda_1}} \dots \frac{\mathbf{v}_{N_s}}{\sqrt{\lambda_{N_s}}} \end{pmatrix}. \quad (3.9)$$

Der Parameter  $N_s$  steht für die Anzahl der verwendeten Vektoren und die zu erstellende Anzahl an Kanälen. Eine Normalisierung der Eigenvektoren, mit der Quadratwurzel der zugehörigen Eigenwerte, ist nicht zwingend erforderlich. Sie sorgt lediglich dafür, dass die Kanäle  $\mathbf{s}_1, \dots, \mathbf{s}_{N_s}$  die gleiche Energie besitzen. Die Anzahl der gefilterten Kanäle

wird so gewählt, dass möglichst 90 % der Energie aus den Stör- und Rauschsignalen unterdrückt wird. Somit wird der Parameter  $N_s$  zu der kleinsten Zahl gewählt, für die gilt:

$$\frac{\sum_{i=1}^{N_s} \lambda_i}{\sum_{j=1}^{N_y} \lambda_j} > 0,1. \quad (3.10)$$

In dieser Gleichung ist der Nenner die gesamte Energie in den Stör- und Rauschsignalen und der Zähler die Energie unter der Verwendung von  $N_s$  Kombinationen.

### 3.2.1.3. Merkmalsextraktion

Zur Detektion einer Frequenz in den  $N_s$  räumlich gefilterten Kanälen, wird die Energie dieser Frequenz und einer Anzahl an  $N_h$  Harmonischen wie folgt ermittelt [57]:

$$\hat{P} = \frac{1}{N_s N_h} \sum_{l=1}^{N_s} \sum_{k=1}^{N_h} \|\mathbf{X}_k^T \mathbf{s}_l\|^2. \quad (3.11)$$

Die Matrix  $\mathbf{X}_k$  ist die Modellmatrix mit den Sinus- und Kosinuspaaren für die  $k$ -te harmonische Frequenz und  $\mathbf{s}_l$  das  $l$ -te Kanalsignal. Für jede der  $N_f$  Frequenzen wird die Signalenergie nach dieser Gleichung berechnet.

Um die Klassifikation des fokussierten Stimulus zu verbessern, wird das Verfahren, wie es in [180] beschrieben wird, verwendet. Dieses Verfahren sieht zuerst eine Umwandlung der absoluten Signalenergien in relative Werte vor, um eine Vergleichbarkeit zwischen den Nutzern und eine Klassifikation unabhängig von nutzerspezifischen Parametern zu erzielen. Jede der  $N_f$  Signalenergien wird wie folgt normalisiert:

$$p_i = \frac{\hat{P}_i}{\sum_{j=1}^{N_f} \hat{P}_j} \text{ mit } \sum_{i=1}^{N_f} p_i = 1. \quad (3.12)$$

Der Wert  $\hat{P}_i$  ist die Signalenergie der  $i$ -ten Frequenz. Zum Schluss ermöglicht die Verwendung der Aktivierungsfunktion Softmax eine stärkere Trennung zwischen den relativen Werten:

$$p'_i = \frac{e^{\alpha p_i}}{\sum_{j=1}^{N_f} e^{\alpha p_j}} \text{ mit } \sum_{i=1}^{N_f} p'_i = 1. \quad (3.13)$$

#### 3.2.1.4. Klassifikation

Zum Schluss findet, wie in [180] beschrieben, eine Klassifikation anhand der zuvor extrahierten Merkmale statt. Eine Frequenz muss für ihre Auswahl drei Kriterien erfüllen. Erstens muss sie die maximale Wahrscheinlichkeit besitzen, zweitens muss sie einen vorher definierten Schwellwert überschreiten und drittens muss es sich bei der Frequenz um eine Stimulationsfrequenz handeln. Somit ergibt sich folgende Klassifikationsregel:

$$C = \begin{cases} \arg \max_i (p'_i), & \text{falls } p'_i \geq \beta_i \text{ und } 1 \leq i \leq N_{sf} \\ 0, & \text{sonst.} \end{cases} \quad (3.14)$$

Der Wert  $p'_i$  ist die Wahrscheinlichkeit der  $i$ -ten Frequenz,  $\beta_i$  der entsprechende Schwellwert und  $N_{sf}$  die Anzahl an Stimulationsfrequenzen. Um die Robustheit der Klassifikation zu erhöhen, empfiehlt es sich, neben den Stimulationsfrequenzen, weitere Frequenzen zu untersuchen. Somit liegt der Index  $i$  im Bereich  $1 \leq i \leq N_f$ , mit  $N_{sf} \leq N_f$ . Der Parameter  $N_f$  steht für die Gesamtanzahl an betrachteten Frequenzen.

#### 3.2.1.5. Wahl der Parameter

In der Arbeit [180] wird der Wert  $\alpha$  mit 0,25 als empirisch ermittelter Wert angegeben. Im Rahmen des sBCI-Projektes [110] wurde der Wert  $\alpha$  ebenfalls auf 0,25 gesetzt. Wie in der Dissertation [110] gezeigt, führt ein kurzes Zeitfenster und geringer Schwellwert zwar zu einer hohen Klassifikationsgeschwindigkeit, jedoch kann es dabei leicht zu fehlerhaften Klassifikationen und somit zu einer geringen Klassifikationsgenauigkeit kommen. Aufgrund der Anordnung der LEDs am sBCI-Helm befinden sich alle Stimuli im Ge-

sichtsfeld des Nutzers. Zusätzlich ist der Abstand zwischen einer LED und dem Auge des Nutzers mit ca. 3 cm sehr gering. Durch diesen Umstand wird die Wahrscheinlichkeit einer fehlerhaften Klassifikation zusätzlich erhöht. Als Kompromiss zwischen Klassifikationsgenauigkeit und -geschwindigkeit wurde in dem sBCI-Projekt das Zeitfenster auf 2 s und der Schwellwert auf 75 % gesetzt. Untersucht wurde neben der Grundfrequenz zusätzlich die 2. Harmonische. Für einen Vergleich der Ergebnisse dieser Dissertation mit denen aus dem sBCI-Projekt werden dieselben Werte verwendet.

### 3.2.2. ERD/ERS-BCI

In diesem Abschnitt wird der Algorithmus zur Erkennung von Bewegungsvorstellungen erläutert, der bereits im Rahmen des sBCI-Projektes [113] Verwendung fand und in der Arbeit [98] erstmals beschrieben wurde. Eine ausführliche Beschreibung des Algorithmus liefert die Dissertation [112].

Der Algorithmus benötigt die in einer Kalibrierungssitzung aufgenommenen Daten des Probanden. Diese Daten dienen der individuellen Anpassung des Klassifikators an den Nutzer. Der zu erstellende Klassifikator ist in der Lage, den intentionalen Kontrollzustand (engl. Intentional Control (IC)) vom Nichtkontrollzustand (engl. Non Control (NC)) zu unterscheiden. Weiterhin kann er zwischen drei IC-Zuständen bzw. drei Bewegungsvorstellungen unterscheiden: die der linken Hand ( $IC_{LH}$ ), die der rechten Hand ( $IC_{RH}$ ) und die der beiden Füße ( $IC_F$ ).

#### 3.2.2.1. Signalvorverarbeitung

Bewegungsvorstellungen bewirken Veränderungen im EEG-Energiespektrum. Da diese Veränderungen hauptsächlich im  $\mu$ - und  $\beta$ -Frequenzbereich auftreten, wird die Analyse des Spektrums auf diese beiden Frequenzbereiche beschränkt. Die beiden Frequenzbänder variieren jedoch hinsichtlich der mittleren Frequenz und der Bandbreite von Nutzer



zu Nutzer. In einem ersten Schritt wird daher die genaue Position der beiden Frequenzbänder anhand der Trainingsdaten bestimmt.

Um die Unterschiede in den räumlichen Merkmalen zwischen den verschiedenen Bewegungsvorstellungen zu verstärken, findet im nächsten Schritt die Berechnung von räumlichen Filtern mit Hilfe der Trainingsdaten statt. Die berechneten Filter dienen anschließend der Filterung aller Signale.

### **Identifizierung der individuellen $\mu$ - und $\beta$ -Frequenzbänder**

Zuerst findet im Frequenzbereich von 5 bis 35 Hz eine Filterung der Kalibrierungsdaten mit einem Bandpass statt. Aus den gefilterten Daten werden anschließend die NC-Daten extrahiert. Im nächsten Schritt wird an jedem Kanal der extrahierten Daten ein autoregressives (AR)-Modell angepasst. Die Koeffizienten eines AR-Modells spiegeln Veränderungen im Energiespektrum wieder und ermöglichen dadurch die Bestimmung der individuellen Frequenzbänder [158]. Im Zeitbereich lässt sich das autoregressive Modell durch die folgende Differenzengleichung beschreiben:

$$x(k) = \sum_{n=1}^p a_n x(k-n) + \epsilon(k). \quad (3.15)$$

Hier ist  $x(k)$  der Datenpunkt zum Zeitpunkt  $k$ ,  $a_n$  der  $n$ -te Koeffizient des AR-Modells,  $\epsilon(k)$  eine Zufallskomponente und  $p$  ist die Ordnung des AR-Modells. Die Anpassung der Signale an ein AR-Modell erfolgt mit dem Levinson-Durbin-Algorithmus [43]. Die Ordnung des Modells wird nach dem Schwarz-Informationskriterium (engl. Schwarz Information Criterion (SIC)) wie folgt bestimmt [161]:

$$SIC(p) = \log(\sigma^2) + \frac{2p \log(N)}{N} \quad (3.16)$$

wobei  $p$  die Modellordnung ist,  $\sigma^2$  die Residualvarianz und  $N$  die Anzahl an Datenpunkten in einem einzelnen Segment. Die Modellordnung entspricht dem Minimum

der SIC-Kurve für ungerade  $p \in \{5, \dots, 15\}$ . Wird das bestimmte AR-Modell der Z-Transformation unterzogen und nach  $x(k)$  aufgelöst, so ergibt sich:

$$x(z) = h(z)e(z) \quad (3.17)$$

mit

$$h(z) = \frac{1}{1 - \sum_{n=1}^p a_n z^{-n}}, \quad (3.18)$$

der Übertragungsfunktion des autoregressiven Modells. Unter der Annahme, dass die Übertragungsfunktion lediglich einzelne Pole besitzt, lautet diese wie folgt:

$$h(z) = \sum_{n=1}^p C_n \frac{z}{z - z_n} \quad (3.19)$$

mit  $C_n = \lim_{z \rightarrow z_n} \frac{(z - z_n)h(z)}{z}$  und  $z_n$  der n-ten Polstelle von  $h(z)$ . Die Berechnung der Frequenz  $f_n$  und der Halbwertsbreite  $2\beta_n$ , für die n-te Polstelle  $z_n$  und die Abtastfrequenz  $f_s$ , erfolgt mit den beiden folgenden Gleichungen:

$$f_n = \text{Im}(\ln(z_n)) \frac{f_s}{2\pi}, \quad (3.20)$$

$$\beta_n = -\text{Re}(\ln(z_n)) \frac{f_s}{2\pi}. \quad (3.21)$$

Zum Schluss erfolgt für jeden Kanal eine Auswahl der spektralen Peaks im  $\mu$ - und  $\beta$ -Frequenzbereich. Die k-means Methode sorgt abschließend für eine Kombination der Peaks und liefert als Ergebnis die beiden individuellen Frequenzbänder  $\mu_{ind}$  und  $\beta_{ind}$ . Diese sind für jeden Kanal identisch.

### Berechnung der räumlichen Filter

Zur Berechnung der räumlichen Filter wird das folgende Modell angenommen:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (3.22)$$

wobei  $\mathbf{s}(t) = [s_1(t), \dots, s_m(t)]^T \in \mathbb{R}^{m \times 1}$  sind  $m$  simultan aktive und statistisch unabhängige Quellen,  $\mathbf{x}(t) = [x_1(t), \dots, x_n(t)]^T \in \mathbb{R}^{n \times 1}$  sind  $n$  durch die Elektroden gemessene Signale und  $\mathbf{A} \in \mathbb{R}^{n \times m}$  eine Vermischungsmatrix, deren Element  $a_{ij}$  den Anteil der Quelle  $j$  zum Elektrodensignal  $i$  beschreibt. Nach diesem Modell besteht das durch die Elektrode  $i$  gemessene Signal aus einer Linearkombination der Quellsignale. Die Ursache hierfür besteht in der linearen Überlagerung elektromagnetischer Felder. Gesucht wird die Transformation  $\hat{\mathbf{P}} = \hat{\mathbf{A}}^{-1}$ , um die unvermischten Signale zu erhalten, die die Signale der unabhängigen Quellen approximieren:

$$\hat{\mathbf{s}}(t) = \hat{\mathbf{P}}\mathbf{x}(t). \quad (3.23)$$

Da weder die Quellsignale  $\mathbf{s}(t)$  noch die Vermischungsmatrix  $\mathbf{A}$  bekannt sind, erfolgt eine Schätzung beider Werte ( $\hat{\mathbf{s}}(t)$  und  $\hat{\mathbf{A}}$ ) aus den gemessenen Signalen  $\mathbf{x}(t)$ . Dieses Verfahren wird als Blind Source Separation (BSS) bezeichnet.

Es ist bekannt, dass ERD/ERS-Veränderungen hauptsächlich in den beiden Frequenzbereichen  $\mu$  (7-13 Hz) und  $\beta$  (13-30 Hz) auftreten. Für jeden dieser beiden Frequenzbereiche wird deshalb ein räumlicher Filter geschätzt. Zur Schätzung der beiden Filter  $\mathbf{P}_\mu$  und  $\mathbf{P}_\beta$  findet zunächst eine separate Bandpassfilterung der Trainingsdaten in den beiden Frequenzbereichen statt. Anschließend werden die IC-Daten extrahiert und in partiell überlappende zwei Sekunden lange Zeitintervalle aufgeteilt. Dabei wird angenommen, dass die EEG-Signale in diesem Zeitfenster quasistationär bleiben. Für jedes Datensegment wird die Kovarianzmatrix berechnet. Mit dem FFDiag-Algorithmus [195] erfolgt, durch gleichzeitige Diagonalisierung der zuvor berechneten Kovarianzmatrizen, die Berechnung der beiden räumlichen Filter  $\mathbf{P}_\mu$  und  $\mathbf{P}_\beta$  für jedes Datensegment.

### Räumliche Filterung

Nach der Berechnung der Filter findet die Filterung der extrahierten Trainingsdaten statt. Ein zu klassifizierendes Datensegment wird mit den Filtern des später zu bestimm-

menden optimalen Zeitfensters gefiltert. Die räumliche Filterung der Signale  $\mathbf{x}(t)$  erfolgt für jedes der allgemeinen Frequenzbänder  $b \in \{\mu, \beta\}$  wie folgt:

$$\hat{\mathbf{s}}_b(t) = \hat{\mathbf{P}}_b \mathbf{x}(t). \quad (3.24)$$

### 3.2.2.2. Merkmalsextraktion und -reduktion

Im Anschluss an die Vorverarbeitung findet die Extraktion und Reduktion von Merkmalen statt. Aufgrund der asynchronen Operationsweise des Systems, müssen die Zeitintervalle innerhalb der Trainingsdaten bestimmt werden, die eine Unterscheidung zwischen dem Kontroll- und Nichtkontrollzustand ermöglichen. Eine Reduktion der Merkmale erfolgt, da die Anzahl an Wiederholungen einer Bewegungsvorstellung begrenzt ist. Außerdem sind nicht alle Merkmale relevant für die Klassifikation und einige Merkmale könnten redundant sein.

#### Merkmalsextraktion

Für jeden  $i$ -ten Quellkanal  $\hat{\mathbf{s}}_{i,b}(t)$  wird nach der Filterung das Leistungsdichtespektrum mit der Multitaper-Methode (MTM) [169] berechnet:

$$S_{i,b}(f) = \text{MTM}(\hat{\mathbf{s}}_{i,b}(t)). \quad (3.25)$$

Diese Methode nutzt eine Sequenz von  $N_w = 2\Delta t \Delta f - 1$  orthogonal zueinander liegenden Fenstern, um das Periodogramm des Signals zu berechnen. Dabei wird für jedes Fenster das Periodogramm berechnet und über diese anschließend gemittelt. Der Parameter  $\Delta t$  gibt die Länge des Zeitfensters an und  $\Delta f$  beschreibt die Weite eines spektralen Peaks.

Die nun vorliegenden Leistungsdichtespektren werden innerhalb der individuellen Grenzen  $R = \{\mu_{ind}, \beta_{ind}\}$ , die sich in den allgemeinen Frequenzbändern  $b$  befinden, integriert:

$$S_{i,R} = \sum_{f \in R} S_{i,b}(f). \quad (3.26)$$

Ein einzelnes Merkmal ist wie folgt definiert:

$$X_{i,R} = \log_{10} S_{i,R}. \quad (3.27)$$

Nach dieser Prozedur sind für jedes Datensegment  $N = (\text{Anzahl an Quellkanälen}) \times (\text{Anzahl an individuellen Frequenzbändern})$  Merkmale vorhanden.

### **Reduktion der Merkmale und Auswahl des Zeitintervalls zur Unterscheidung zwischen dem Nichtkontrollzustand und jedem der Kontrollzustände**

Für jeden Kontrollzustand  $IC_k$  ( $k \in \{RH, LH, F\}$ ) und dem Nichtkontrollzustand  $NC$  der Trainingsdaten sind mehrere Merkmalsvektoren vorhanden. Zum einen aufgrund der unterschiedlichen Zeitintervalle bei den Bewegungsvorstellungen, zum anderen aufgrund der Wiederholungen pro Klasse. In diesem Schritt werden nun die Merkmale extrahiert, die eine optimale Unterscheidung zwischen dem Nichtkontrollzustand und jedem der Kontrollzustände ermöglichen. Am Ende soll für jede Unterscheidung zwischen  $IC_k$  und  $NC$  nur ein Satz an Vektoren pro Klasse übrig bleiben. Dieser Satz an Vektoren entstammt dem besten Zeitintervall der jeweiligen Klasse, wobei für die NC-Klasse nur ein Zeitintervall betrachtet wird.

Um dieses Ziel zu erreichen, erfolgt, separat für jedes Zeitintervall und jeden Kontrollzustand  $IC_k$ , eine Reduktion der Merkmale des Nichtkontrollzustandes und des entsprechenden Kontrollzustandes. Für jede IC-Klasse und jedes Zeitintervall wird anschließend die Mahalanobis Distanz (MD) zu den Merkmalen der NC-Klasse berechnet. Zum Schluss wird für jede Klasse das Zeitintervall und der Datensatz mit der größten Distanz ausgewählt. Die Reduktion der Merkmale eines zu klassifizierenden Datensegmentes erfolgt entsprechend den Trainingsdaten.

Die Reduzierung der Merkmale erfolgt durch iterative Anwendung der Maximum Relevanz Minimum Redundanz (MRMR)-Formel [133]:

$$J_n = I(X_n; Y) - \frac{1}{n-1} \sum_{k=1}^{n-1} I(X_n; X_k). \quad (3.28)$$

Die Merkmale mit der höchsten Bewertung  $J$  bilden den reduzierten Merkmalsvektor. Diese Merkmale besitzen die höchste Relevanz bezüglich der Klasse und sind gleichzeitig möglichst redundant. Die Iterationen stoppen bei dem  $k$ , für welches  $J_k < 0$  gilt. Der Term

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p_1(x)p_2(y)} \quad (3.29)$$

misst die gemeinsame Information zweier Zufallsvariablen  $X$  und  $Y$ . Die Merkmale sind in diesem Fall  $X$  und die dazugehörigen Klassenbezeichnungen  $Y$ . Die marginalen Wahrscheinlichkeitsverteilungen  $p_1(x)$  und  $p_2(x)$  sowie die gemeinsame Wahrscheinlichkeitsverteilung  $p(x, y)$  werden innerhalb eines Vektors, durch Quantisierung der Merkmale, ermittelt.

Die Mahalanobis Distanz [109] ist ein Distanzmaß im mehrdimensionalen Vektorraum. Zur Berechnung der Distanz, zwischen zwei Sätzen von Merkmalsvektoren  $A$  und  $B$ , ist sie wie folgt definiert:

$$d = \sqrt{(\mu_{\mathbf{A}} - \mu_{\mathbf{B}})^T \mathbf{C}^{-1} (\mu_{\mathbf{A}} - \mu_{\mathbf{B}})} \quad (3.30)$$

wobei  $\mu_{\mathbf{A}} = \{\mu_1^A, \dots, \mu_n^A\}$  und  $\mu_{\mathbf{B}} = \{\mu_1^B, \dots, \mu_n^B\}$  die gemittelten Vektoren der Sätze  $A$  und  $B$  darstellen.  $\mathbf{C}$  ist die gemeinsame Kovarianzmatrix

$$\mathbf{C} = \frac{n_A \mathbf{C}_{\mathbf{A}} + n_B \mathbf{C}_{\mathbf{B}}}{n_A + n_B - 2}, \quad (3.31)$$

gebildet aus den beiden Kovarianzmatrizen  $\mathbf{C}_A$  und  $\mathbf{C}_B$ , die zu den beiden Sätzen  $A$  und  $B$  gehören. Die Parameter  $n_A$  und  $n_B$  stehen für die Anzahl der Datenpunkte in den Vektoren der beiden Datensätze.

### **Reduktion der Merkmale zur Unterscheidung zwischen den Kontrollzuständen**

Der Klassifikator zur Unterscheidung zwischen den Kontrollzuständen nutzt andere Merkmale, als der Klassifikator zur Unterscheidung zwischen dem Nichtkontrollzustand und jedem der Kontrollzustände. Daher werden zunächst, aus den zuvor bestimmten besten Zeitintervallen der Trainingsdaten, die Merkmale der IC-Klassen extrahiert. Anschließend sorgt die iterative Anwendung der MRMR-Formel für eine Reduktion der extrahierten Datensätze. Die Reduktion der Merkmale eines zu klassifizierenden Datensegmentes erfolgt entsprechend den Trainingsdaten.

#### **3.2.2.3. Klassifikation**

Im nächsten Schritt werden die Merkmale der Kalibrierung zum Training der Klassifikatoren verwendet. Die Klassifizierung von Merkmalen erfolgt in zwei Stufen. In der ersten Stufe wird entschieden, ob eine Bewegungsvorstellung vorliegt oder der Nichtkontrollzustand. Liegt eine Bewegungsvorstellung vor, so wird im nächsten Schritt festgestellt, um welche der drei Bewegungsvorstellungen es sich handelt.

### **Training der logistischen Regressionsklassifikatoren zur Unterscheidung zwischen den Kontrollzuständen und dem Nichtkontrollzustand**

Zur Unterscheidung, ob ein Kontroll- oder ein Nichtkontrollzustand vorliegt, werden drei logistische Regressionsklassifikatoren trainiert. Jeder Klassifikator soll zwischen einer der IC-Klassen und der NC-Klasse unterscheiden. Für die Unterscheidung zwischen der Klasse  $IC_k$  und der Klasse  $NC$  liegt eine Merkmalsmatrix  $\mathbf{X} \in \mathbb{R}^{n \times m}$  vor, bestehend aus  $n$  Messungen und  $m$  Merkmalen. Die Wahrscheinlichkeitsbeziehung zwischen den

Merkmale  $\mathbf{X}_i$  der  $i$ -ten Messung und dem Ereignis  $Y = IC$  lässt sich über die folgende logistische Funktion (Logit-Funktion) herstellen:

$$P_i(Y = IC) = \frac{1}{1 + e^{-z_i}} \quad (3.32)$$

mit

$$z_i = b_0 + \sum_{j=1}^m b_j \mathbf{X}_{ij}. \quad (3.33)$$

Die Modellparameter  $b_j$  werden mit der Maximum-Likelihood-Methode geschätzt. Das Klassifikationskriterium lautet wie folgt:

$$Y_i = \begin{cases} IC, & \text{falls } (P_i(Y = IC) - p_u) > 0,5 \\ NC, & \text{sonst.} \end{cases} \quad (3.34)$$

Die untere Grenze des Konfidenzintervalls  $p_u$  wird aus den Wahrscheinlichkeiten der Kalibrierungsdaten bestimmt.

### **Training eines multinomialen logistischen Regressionsklassifikators zur Unterscheidung zwischen den Kontrollzuständen**

Klassifiziert einer der drei zuvor erstellten Klassifikatoren einen Merkmalsvektor als Bewegungsvorstellung, so wird in einer zweiten Stufe bestimmt, um welche der drei Bewegungsvorstellungen es sich handelt. Der Klassifikator der zweiten Stufe nutzt die beiden folgenden logistischen Regressionsmodelle mit der dritten Bewegungsvorstellung als Referenzklasse:

$$\ln \frac{P_i(Y = IC_{LH})}{P_i(Y = IC_{RH})} = b_{01} + \sum_{j=1}^m b_{j1} \mathbf{X}_{ij}, \quad (3.35)$$

$$\ln \frac{P_i(Y = IC_F)}{P_i(Y = IC_{RH})} = b_{02} + \sum_{j=1}^m b_{j2} \mathbf{X}_{ij}. \quad (3.36)$$



Die Maximum-Likelihood-Methode schätzt auch hier die Parametervektoren  $\mathbf{b}_1$  und  $\mathbf{b}_2$ . Die Wahrscheinlichkeitsbeziehungen, zwischen den Merkmalen  $\mathbf{X}_i$  der i-ten Messung und den drei Bewegungsvorstellungen, sind wie folgt zu berechnen:

$$P_i(Y = \text{IC}_{\text{LH}}) = \frac{e^{\mathbf{b}_1 \mathbf{X}_i}}{1 + e^{\mathbf{b}_1 \mathbf{X}_i} + e^{\mathbf{b}_2 \mathbf{X}_i}}, \quad (3.37)$$

$$P_i(Y = \text{IC}_{\text{F}}) = \frac{e^{\mathbf{b}_2 \mathbf{X}_i}}{1 + e^{\mathbf{b}_1 \mathbf{X}_i} + e^{\mathbf{b}_2 \mathbf{X}_i}}, \quad (3.38)$$

$$P_i(Y = \text{IC}_{\text{RH}}) = \frac{1}{1 + e^{\mathbf{b}_1 \mathbf{X}_i} + e^{\mathbf{b}_2 \mathbf{X}_i}}. \quad (3.39)$$

Das Klassifikationskriterium der zweiten Stufe lautet:

$$Y_i = \begin{cases} \text{IC}_{\text{LH}}, & \text{falls } (P_i(Y = \text{IC}_{\text{LH}}) - p_u) > 0,5 \\ \text{IC}_{\text{F}}, & \text{falls } (P_i(Y = \text{IC}_{\text{F}}) - p_u) > 0,5 \\ \text{IC}_{\text{RH}}, & \text{falls } (P_i(Y = \text{IC}_{\text{RH}}) - p_u) > 0,5 \\ \text{NC}, & \text{sonst.} \end{cases} \quad (3.40)$$

Die untere Grenze des Konfidenzintervalls  $p_u$  wird aus den Wahrscheinlichkeiten der Kalibrierungsdaten bestimmt.

Zur Reduzierung von Fehlklassifizierungen speichert der Klassifikator zunächst die Ergebnisse in einen Puffer, der die Ausgaben der letzten fünf Sekunden speichert. Erst, wenn eine Bewegungsvorstellung 5 Mal in diesem Speicher vorhanden ist, wird diese als Steuerkommando übernommen.

### 3.2.3. Nutzerschnittstelle und Steuermethoden

Zum Testen des sBCI-Systems wurde, im Rahmen des sBCI-Projektes [113], eine Mensch-Maschine-Schnittstelle implementiert, die es ermöglicht, ein Internet-Radio, einen Kühlschrank und eine Mikrowelle zu steuern. Die Steuerung eines Internet-Radios ist in ihrer Komplexität ähnlich zu der Steuerung eines Assistenzroboters. Der Kühlschrank und die




Abbildung 3.3.: Hybrides ERD/ERS- und SSVEP-BCI mit sequentieller Verarbeitung. Das ERD/ERS-BCI fungiert als Schalter, der das SSVEP-BCI und die LEDs aktiviert.

Mikrowelle stellen hingegen einfach zu steuernde Geräte dar. Derzeit sind die folgenden Funktionalitäten verfügbar:

- **Internet-Radio:** An/Aus, Kanalauswahl von 0 bis 9, Musikquellenauswahl (Internet-Radio, FM-Radio, Musik-Archiv), Menünavigation (hoch, runter, links, rechts, auswählen), Lautstärkeänderung (hoch/runter), Standard-Abspielfunktionen (Pause, Weiter, Stoppen, Auswahl des vorherigen oder nächsten Liedes)
- **Kühlschrank:** Öffnen und Schließen der Tür
- **Mikrowelle:** Kochzeiteinstellung, Starten des Kochvorgangs, Öffnen der Tür

Die Nutzerschnittstelle erhält die Klassifikationsergebnisse als Eingangssignal über eine Netzwerkverbindung und sendet Steuerkommandos an die ausgewählten Geräte über eine Infrarotschnittstelle. Jedes Kommando erzeugt dabei eine akustische und visuelle Rückmeldung an den Nutzer. Das ERD/ERS-BCI dient zur Auswahl des zu steuernden Gerätes und zum Einschalten des SSVEP-BCIs und des visuellen Stimulators. Mit dem SSVEP-BCI erfolgt die Steuerung des ausgewählten Gerätes. Der sequentielle Wechsel zwischen beiden Modalitäten ist in der Abbildung 3.3 dargestellt.

In der Abbildung 3.4 ist die grafische Benutzerschnittstelle des sBCI-Systems zu sehen. Auf der linken Seite sind alle zu steuernden Geräte aufgelistet. Mit der Bewegungsvorstellung der linken Hand und der rechten Hand kann der Nutzer innerhalb der Liste hoch bzw. runter navigieren. Über die Bewegungsvorstellung der beiden Füße lässt sich ein Gerät auswählen. Die Zuordnung der Bewegungsvorstellungen zu den Steuerkom-

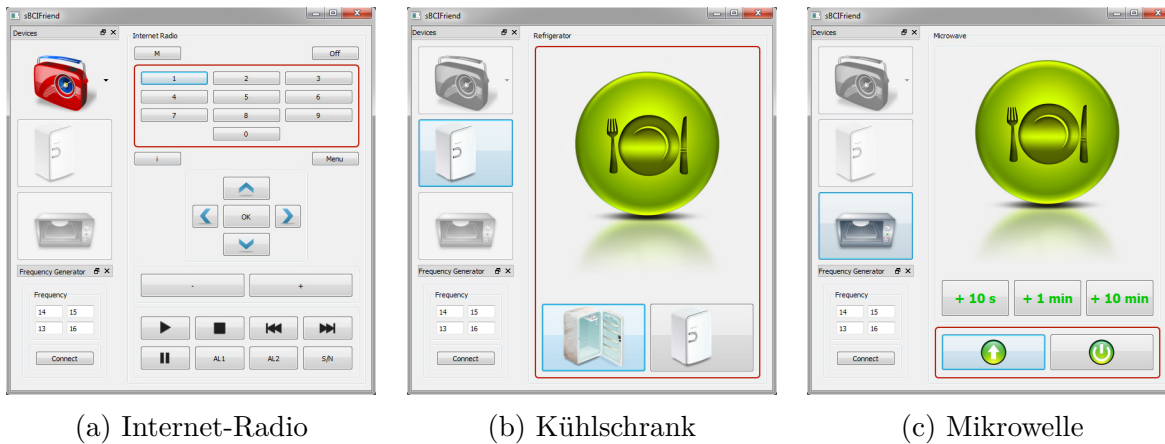


Abbildung 3.4.: Die sBCI-Benutzeroberfläche zur Steuerung eines Internet-Radios, eines Kühlschranks und einer Mikrowelle. Auf der linken Seite der Oberfläche befindet sich die Geräteauswahlliste. Die rechte Seite ändert sich entsprechend des ausgewählten Gerätes und ermöglicht dessen Steuerung. Alle Icons dieser Schnittstelle stammen von [www.iconarchive.com](http://www.iconarchive.com).

mandos ist in der Abbildung 3.5a zu sehen. Der Startpunkt der Geräteauswahl befindet sich beim Internet-Radio. Bei der Geräteauswahlliste handelt es sich um eine Ringliste.

Sobald ein Gerät ausgewählt wird, visualisiert die rechte Seite der Oberfläche die Funktionalitäten des ausgewählten Gerätes. Die vier LEDs des sBCI-Helmes beginnen zu blinken und der Nutzer kann über die Konzentration auf diese Stimulanzen das ausgewählte Gerät steuern. Eine Übersicht über die Zuordnung der vier LEDs zu den Steuerkommandos lässt sich der Abbildung 3.5b entnehmen. Die Steuerung mit dem SSVEP-BCI ist in zwei hierarchischen Ebenen angeordnet. In der ersten Ebene kann der Nutzer mit Hilfe von zwei Kommandos zwischen Untermenüs wechseln. Untermenüs gruppieren Aktionen, die zu der gleichen Kategorie gehören. Ein drittes Kommando sorgt für den Eintritt in das Untermenü. Das vierte Kommando ermöglicht die Deaktivierung der LEDs und die Rückkehr des Gerätecursors zu seiner Ausgangsposition. Um die Navigation zu beschleunigen, ist es möglich, direkt nach der Auswahl des Gerätes sofort zu den Untermenüs zu springen. Jeder LED ist dabei ein Untermenü zugeordnet. Der Nutzer befindet sich innerhalb der zweiten Steuerebene, sobald er ein Untermenü betritt. In dieser Ebene kann der Nutzer über zwei Kommandos zwischen den einzelnen Aktionen wechseln. Ein



Abbildung 3.5.: Zuordnung der Bewegungsvorstellungen und der LEDs zu den Steuerkommandos.

drittes Kommando sorgt für die Ausführung der Aktion. Mit dem vierten Kommando kann der Nutzer das Untermenü verlassen. In diesem Fall kehrt das System zur ersten Ebene zurück.

### 3.3. Test des sBCI-Systems

Im Rahmen dieser Studie wurde die Steuerung von Haushaltsgeräten mit dem sBCI-System getestet. Die Auswahl der Geräte erfolgte mit dem ERD/ERS-BCI und die Steuerung der Geräte mit dem SSVEP-BCI. Trotz der Verwendung von komplexen Signalverarbeitungsalgorithmen müssen die Nutzer ein langes Training absolvieren, um ein auf Bewegungsvorstellungen basiertes BCI sicher bedienen zu können. Daher wurden die Probanden in den ersten Sitzungen ausschließlich auf die Verwendung von Bewegungsvorstellungen trainiert.

#### 3.3.1. Teilnehmer der Studie

An der Studie nahmen 9 Frauen und 7 Männer teil, die über keine vorherige BCI-Erfahrung verfügten. Das Alter der Probanden lag zwischen 18 und 66 Jahren und das Durchschnittsalter betrug  $24,78 \pm 10,67$  Jahre. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die ex-

perimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten der Universität Bremen. Für ihre Teilnahme erhielten die Studenten wahlweise eine Aufwandsentschädigung in Höhe von 10 € pro Stunde oder sie konnten durch ihre Teilnahme Probandenstunden ableisten. Jeder Proband nahm an fünf Sitzungen teil, die an unterschiedlichen Tagen stattfanden. Die ersten drei Sitzungen dienten ausschließlich dem Training von Bewegungsvorstellungen. An den letzten beiden Sitzungen wurde zusätzlich die Steuerung von Haushaltsgeräten getestet.

Die Versuche fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### 3.3.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale und die im Helm integrierten LEDs zur visuellen Stimulation für das SSVEP-Paradigma. Zur Erkennung von SSVEPs wurden 8 Kanäle ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex verwendet. Die Detektion von Bewegungsvorstellungen erfolgte über 14 Kanäle ( $FC_3$ ,  $FC_z$ ,  $FC_4$ ,  $C_5$ ,  $C_3$ ,  $C_1$ ,  $C_z$ ,  $C_2$ ,  $C_4$ ,  $C_6$ ,  $CP_3$ ,  $CP_z$ ,  $CP_4$ ,  $P_z$ ), die den sensomotorischen Bereich des Gehirns abdeckten. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

#### 3.3.3. Training von Probanden für Bewegungsvorstellungen

Zum Trainieren der Probanden für Bewegungsvorstellungen wurde die Software des sBCI-Systems aus Abschnitt 3.2 mit dem ERD/ERS-BCI verwendet. Anstelle die Klas-

sifikationsergebnisse an die Anwendung zur Steuerung von Geräten zu senden, sendet die Signalverarbeitung die Ergebnisse an die in der Arbeit [98] beschriebene Trainingsanwendung. Bei dieser Anwendung handelt es sich um eine BCI2000-Anwendung. Diese ermöglicht ein Training der Bewegungsvorstellung der linken und rechten Hand sowie die der beiden Füße. Das Programm operiert synchron, da die vorzustellende Bewegung vom System vorgegeben wird. In einem ersten Schritt nimmt das Programm die Trainingsdaten für eine spätere Kalibrierung der nutzerspezifischen Parameter auf. Während der Aufnahme der Trainingsdaten erhält der Nutzer keine Rückmeldung vom System, da in dieser Phase keine Signalverarbeitung stattfindet. Nach der Aufnahme der Daten erfolgt die Kalibrierung mit dem Algorithmus aus Abschnitt 3.2.2. Anschließend lässt sich das Programm zum Trainieren der Bewegungsvorstellungen nutzen. Während des Trainings erhält der Nutzer eine Rückmeldung vom System, um seine Fähigkeit der Bewegungsvorstellung zu verbessern. Die Signalverarbeitung nutzt die zuvor erstellten Kalibrierungsparameter.

### **3.3.3.1. Versuchsprotokoll**

Die Probanden trainierten an insgesamt fünf verschiedenen Tagen ihre Bewegungsvorstellungen. Jede Sitzung dauerte zwei Stunden inklusive Erläuterung der Aufgabenstellung, Präparierung des sBCI-Helms und dem Waschen der Haare.

Die erste Sitzung startete mit insgesamt vier Kalibrierungsdurchläufen. Bei jeder weiteren Sitzung wurde, je nach Leistung des Nutzers, entweder neu kalibriert oder die Parameter von der letzten Sitzung verwendet. In jedem Durchlauf wurde jede Bewegungsvorstellung 10 Mal wiederholt. Das Programm forderte die Nutzer auf, sich die Bewegung der linken Hand, der rechten Hand oder die der beiden Füße vorzustellen und dabei die Bewegung der Glieder zu vermeiden. Somit wurden 30 Wiederholungen pro Durchlauf, 40 Wiederholungen pro Bewegungsvorstellung und 120 Wiederholungen




Abbildung 3.6.: Zeitlicher Ablauf der Kalibrierung von Bewegungsvorstellungen. Während der Stimulus-Phase leuchtet einer der drei Pfeile auf und der Proband soll sich die entsprechende Bewegungsvorstellung solange vorstellen, bis das Leuchten aufhört. Anschließend folgt eine Ruhepause (ISI). Der Wechsel von Stimulus-Phase und ISI wird so oft wiederholt, bis für jede Bewegungsvorstellung ausreichend Daten vorhanden sind.

insgesamt durchgeführt. Zwischen den einzelnen Durchläufen erhielten die Probanden die Gelegenheit für eine Pause.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist in der Abbildung 3.6 zu sehen. In der Pre-Run-Phase erhält der Proband für 5 s Gelegenheit, sich auf den Durchlauf einzustellen. Während der anschließenden Stimulus-Phase leuchtet einer der drei Pfeile für 4 s auf. Innerhalb dieser Phase soll sich der Proband die entsprechende Bewegung wiederholt vorstellen. Zeigt der Pfeil nach links oder rechts, so soll die Bewegungsvorstellung der linken bzw. rechten Hand erfolgen. Die vorzustellende Bewegung soll ein kontinuierliches Öffnen und Schließen der jeweiligen Hand sein. Der Pfeil nach oben steht für die Bewegungsvorstellung der beiden Füße. Hier soll sich der Proband das Greifen eines Objektes mit beiden Füßen vorstellen. Nach einem Stimulus folgt das ISI für 5 s, in dem der Proband Zeit für eine Pause erhält. Der Wechsel von Stimulus-Phase und ISI erfolgt so oft, bis von jeder Bewegungsvorstellung 10 Wiederholungen vorhanden sind. Die Reihenfolge der Pfeilrichtungen und somit der Bewegungsvorstellungen wird vom Programm zufallsgeneriert. Der Balken am unteren Bildschirmrand zeigt den aktuellen Fortschritt an.

Nach der Kalibrierung der nutzerspezifischen Parameter mussten die Probanden bis




Abbildung 3.7.: Zeitlicher Ablauf des Trainings von Bewegungsvorstellungen. In der Pre-Feedback-Phase wird die vorzustellende Bewegung angekündigt. Anschließend muss sich der Proband die Bewegung vorstellen, um den entsprechenden Pfeil mit grünen Balken zu füllen. Innerhalb der Post-Feedback-Phase erhält der Proband eine Rückmeldung über seine Leistung. Danach findet eine Ruhepause statt (Inter-Trial-Intervall (ITI)). Der Vorgang lässt sich beliebig oft wiederholen.

zu sechs Trainingsdurchläufe absolvieren. In der ersten Sitzung lediglich drei Wiederholungen aufgrund der anfänglichen Kalibrierung. War bei den weiteren Sitzungen keine erneute Kalibrierung notwendig, konnten die Probanden sechs Durchläufe in der zweistündigen Sitzung durchführen. Die während des Trainings aufgenommenen Daten ermöglichten eine Aktualisierung der nutzerspezifischen Parameter. Bei den letzten beiden Sitzungen wurde nur ein Trainingsdurchlauf durchgeführt, da im Anschluss die Steuerung von Haushaltsgeräten getestet wurde. In jedem Durchlauf mussten die Probanden jede Bewegungsvorstellung 10 Mal wiederholt trainieren. Sie trainierten die Bewegungsvorstellung der linken Hand, der rechten Hand und die der beiden Füße. Somit bestand ein Trainingsdurchlauf aus insgesamt 30 Wiederholungen. Nach jedem Durchlauf erhielten die Probanden Gelegenheit für eine Pause.

In der Abbildung 3.7 ist der zeitliche Ablauf eines Trainingsdurchlaufes zu sehen. Jeder Durchlauf startet mit einer Pre-Run-Phase von 5 s, in der sich der Proband auf den Durchlauf einstellen kann. Das Training einer Bewegungsvorstellung startet mit der Pre-Feedback-Phase. In dieser Phase wird einer der drei Pfeile für 1 s hellblau hervorgehoben, um die vorzustellende Bewegung anzukündigen. Wird der linke oder der rechte Pfeil hervorgehoben, so soll der Proband sich die Bewegung der linken bzw. der rechten Hand vorstellen. Beim oberen Pfeil wird die Bewegungsvorstellung der beiden Füße



verlangt. Anschließend folgt die Feedback-Phase, in der sich der Proband die verlangte Bewegung vorstellen soll. Der Pfeil wechselt seine Farbe zu dunkelblau und jede korrekte Bewegungsvorstellung führt zu einem grünen Balken innerhalb des Pfeiles. Eine falsch erkannte Bewegungsvorstellung führt zu einem hellblauen Balken in einem der beiden anderen Pfeile. Die Feedback-Phase endet, sobald fünf Balken in einem der drei Pfeile vorhanden sind oder das Zeitlimit von 15 s vorüber ist. In der darauffolgenden Post-Feedback-Phase wird dem Probanden für 1 s das Ergebnis präsentiert. Ist der korrekte Pfeil gefüllt, erhält der Proband eine positive, andernfalls eine negative akustische und visuelle Rückmeldung. Falls kein Pfeil gefüllt ist, erhält der Proband keine Rückmeldung. Im Anschluss folgt das ITI für 5 s. Alle Pfeile nehmen in dieser Phase ihre ursprüngliche Farbe (grau) an und der Proband kann eine Pause einlegen. Das Training der nächsten Bewegungsvorstellung beginnt anschließend mit der Pre-Feedback-Phase. Der Durchlauf endet, sobald jede Bewegungsvorstellung 10 Mal trainiert worden ist. Die Reihenfolge der Pfeilrichtungen, und somit der Bewegungsvorstellungen, wird vom Programm zufallsgeneriert. Der Balken am unteren Bildschirmrand zeigt den aktuellen Fortschritt an.

#### 3.3.3.2. Ergebnisse

In der Abbildung 3.8 sind für jeden Probanden die höchsten Genauigkeiten der ersten drei Trainingssitzungen dargestellt. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle A.3. Die Genauigkeit eines Durchlaufs entspricht dem Anteil der korrekt gefüllten Pfeile an den zu absolvierenden Wiederholungen.

Eine Verbesserung der Leistung wurde von 11 Probanden erreicht. Diese Probanden erzielten in der zweiten oder dritten Sitzung eine höhere Genauigkeit als in der ersten Sitzung. Von diesen 11 Probanden erzielten 3 Probanden eine stetige Verbesserung der Genauigkeit. Bei 5 Probanden blieb die Genauigkeit fast konstant. Auffällig ist, dass die Genauigkeiten von drei dieser Probanden bereits bei der ersten Sitzung sehr hoch waren.




Abbildung 3.8.: Die maximalen Genauigkeiten der Probanden beim Training von Bewegungsvorstellungen an drei Sitzungen.

Eine Verbesserung von Genauigkeiten über 90 % ist somit schwer zu erreichen. Lediglich bei 5 Probanden verringerte sich die Genauigkeit über die Sitzungen.

Eine Übersicht über die Verteilungen der von den Probanden erreichten Genauigkeiten ist in der Abbildung 3.9 zu sehen. Jeder Verteilung liegen alle ermittelten Genauigkeiten eines Probanden zugrunde. Wie in dem Diagramm zu sehen, lagen die Genauigkeiten fast immer über 33 %. Dies ist damit zu erklären, dass fast jeder der Probanden in der Lage war, sich eine der drei Bewegungen sehr gut vorzustellen. Die Mehrheit der Probanden erreichte Genauigkeiten bis zu 66 %. Diese Probanden waren in der Lage, mindestens zwei Bewegungsvorstellungen zu erlernen. Ein Drittel der Probanden konnte sich alle drei Bewegungen vorstellen und erreichte somit Genauigkeiten über 66 %.

### 3.3.4. Steuerung von Haushaltsgeräten

Nach dem Training der Bewegungsvorstellungen waren die Probanden in der Lage, Haushaltsgeräte auszuwählen und zu steuern. In diesem Versuch mussten die Probanden ein Internetradio, eine Mikrowelle und einen Kühlschrank bedienen. Das ERD/ERS-BCI




Abbildung 3.9.: Verteilungen der von den Probanden erreichten Genauigkeiten beim Training von Bewegungsvorstellungen. Jeder Verteilung liegen alle ermittelten Genauigkeiten eines Probanden zugrunde.

ermöglichte die Auswahl eines Gerätes und die Steuerung des ausgewählten Gerätes erfolgte über das SSVEP-BCI. Die Signalverarbeitung der EEG-Signale und die Steuerung der Geräte erfolgte mit der Software aus dem sBCI-Projekt, welche ausführlich in Abschnitt 3.2 beschrieben wurde. Die Stimulationsfrequenzen für das SSVEP-BCI wurden wie folgt festgelegt: 13 Hz (LED unten links), 14 Hz (LED oben links), 15 Hz (LED oben rechts) und 16 Hz (LED unten rechts). Zusätzlich zu den Stimulationsfrequenzen wurden bei der Signalverarbeitung keine weiteren Frequenzen betrachtet.

#### 3.3.4.1. Versuchsprotokoll

Die Probanden mussten die fünf Aufgaben aus der Tabelle 3.1 absolvieren. Die Aufgaben wurden so gewählt, dass jedes der drei Geräte mindestens einmal bedient werden musste. Vor der eigentlichen Versuchsdurchführung wurde das Steuerungskonzept dem Probanden erläutert. Jeder Proband erhielt die Gelegenheit, sich vorher mit der hybriden Steuerung vertraut zu machen. Eine Aufgabe begann mit der Auswahl eines Gerätes über das ERD/ERS-BCI und endete mit dem Ausschalten der LEDs über das SSVEP-

Tabelle 3.1.: Aufgaben zur Steuerung von Haushaltsgeräten mit dem sBCI-System.

Aufgabe	Haushaltsgerät	Beschreibung
1	Internetradio	Kanal 5 einschalten
2	Internetradio	Lautstärke um drei Einheiten erhöhen
3	Kühlschrank	Tür öffnen und schließen
4	Mikrowelle	Kochzeit auf 11:10 Minuten setzen und die Mikrowelle starten
5	Mikrowelle	Tür öffnen

BCI nach Erledigung der Aufgabe. Je nach Leistung des Probanden wurde jede Aufgabe zwischen 3 und 5 Mal wiederholt.

#### 3.3.4.2. Ergebnisse

Zur Evaluierung des ERD/ERS-BCIs wurden die Zeiten der Probanden zur Erzeugung eines Kommandos berechnet, da das Paradigma als Schalter fungiert. Hierfür wurde die Zeit zur Auswahl des Gerätes gemessen und durch die benötigte Anzahl an Kommandos dividiert. Die Parameter Genauigkeit und ITR sind, aufgrund der geringen Anzahl an benötigten Kommandos (1 bis 2 Kommandos sind zur Auswahl notwendig), nicht aussagekräftig genug. An dieser Stelle interessiert die benötigte Zeit zum Einschalten des Stimulators, wenn nur ein Kommando verwendet wird.

Für das SSVEP-BCI wurden die Genauigkeiten und die ITR für jeden einzelnen Versuch ermittelt. Eine ausführliche Beschreibung der beiden Parameter lässt sich dem Abschnitt 2.5 entnehmen. Die Genauigkeit ergibt sich aus dem Verhältnis der korrekten Kommandos zu allen erkannten Kommandos. Unter korrekten Kommandos sind alle Kommandos zu verstehen, die eine schnellstmögliche Bearbeitung der zu erledigenden Aufgabe ermöglichen. Die Anzahl an Kommandos beträgt vier aufgrund der vier LEDs des sBCI-Helms. Zur Berechnung der ITR wurde die Zeit ab der Auswahl des Gerätes bis zum Ausschalten der LEDs ermittelt.

Von den 16 Teilnehmern der Studie waren 15 in der Lage, die Geräte mit Bewegungsvorstellungen auszuwählen. Lediglich ein Proband war nach den drei Trainingssitzungen




Abbildung 3.10.: Die pro Kommando benötigten Zeiten der Probanden bei der Auswahl von Haushaltsgeräten mit dem ERD/ERS-BCI.

nicht in der Lage, das ERD/ERS-BCI zu verwenden. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle A.1. Eine Übersicht über die Leistung der einzelnen Probanden liefert das Diagramm in der Abbildung 3.10. Das Diagramm zeigt die für jeden Probanden im Mittel benötigte Zeit zur Erzeugung eines Kommandos sowie den gesamten Mittelwert. Im Mittel wurde eine Zeit von  $18,47 \pm 22,25$  s pro Kommando benötigt. Die minimal mögliche Zeit beträgt 650 ms. Die geringste Zeit benötigte Proband 11 mit 6,34 s und die höchste Zeit Proband 9 mit 45,25 s. Die Verteilung der benötigten Zeiten ist in der Abbildung 3.11a zu sehen. Der Verteilung liegen alle ermittelten Zeiten zugrunde. Abgesehen von mehreren Ausreißern, liegen die Zeiten immer unter 38,81 s. 75 % aller ermittelten Zeiten liegen unter 20,59 s. Das beste Ergebnis liegt bei 2,22 s.

Alle 16 Probanden waren nach einem kurzen Test des SSVEP-BCIs in der Lage, die ausgewählten Geräte zu bedienen. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle A.2. Die Leistung der einzelnen Probanden ist in der Abbildung 3.12 zu sehen. Das Diagramm zeigt für jeden Probanden die gemittelte Genauigkeit und ITR sowie die gesamten Mittelwerte. Im Mittel wurde eine Genauigkeit von  $87,27 \pm 12,33$  % und eine ITR von  $15,99 \pm 9,29$  bits/min erreicht. Die maximal mögliche ITR betrug

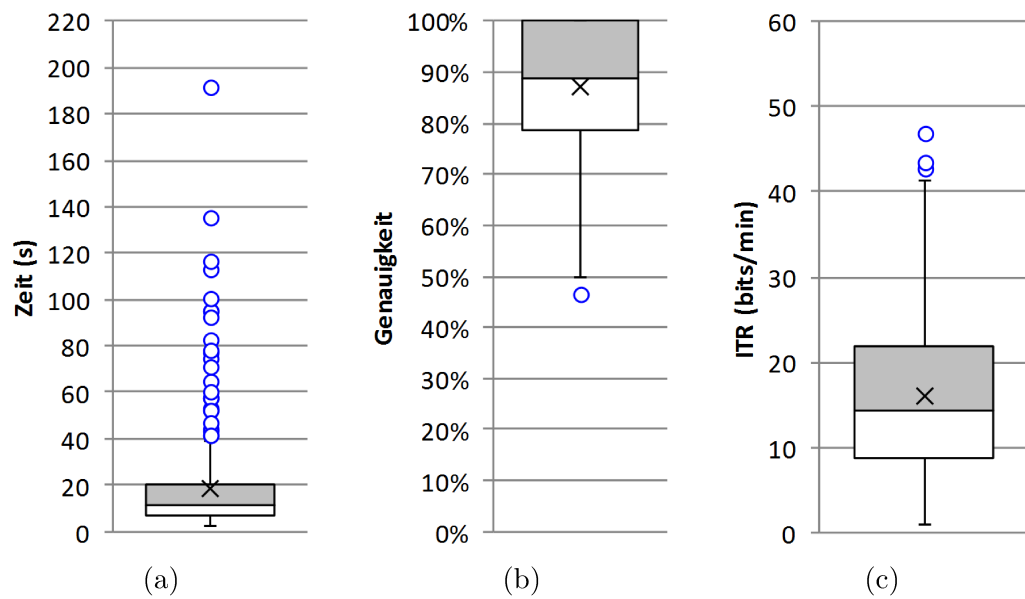


Abbildung 3.11.: Verteilungen der Zeiten pro Kommando (a) beim ERD/ERS-BCI und der Genauigkeiten (b) und der ITR (c) beim SSVEP-BCI. Den Verteilungen liegen alle ermittelten Werte zugrunde.




Abbildung 3.12.: Genauigkeiten und Informationstransferraten der Probanden bei der Steuerung von Haushaltsgeräten mit dem SSVEP-BCI.

60 bits/min, da nach jedem Kommando das System eine Ruhepause von 2 s vorgab. Mit einer Genauigkeit von 93,64 % und ITR von 24,97 bits/min erreichte Proband 1 das beste Ergebnis. Das schlechteste Ergebnis erzielte Proband 12 mit einer Genauigkeit von 71,03 % und ITR von 5,13 bits/min. In den Abbildungen 3.11b und 3.11c sind die Verteilungen aller ermittelten Genauigkeiten und ITR zu sehen. Die Genauigkeit liegt fast immer über 50 %, wobei 75 % aller Werte zwischen 78,76 und 100,00 % liegen. Bei der ITR liegen 75 % der Werte zwischen 8,73 und 41,27 bits/min. Lediglich 25 % der Werte liegen über 21,87 bits/min. Die geringste Geschwindigkeit wurde mit 0,78 bits/min erreicht.

#### 3.3.5. Diskussion der Ergebnisse

Das ERD/ERS-BCI lieferte für die Verwendung als Schalter ausreichende Ergebnisse. Nach bereits drei Trainingssitzungen waren fast alle Probanden in der Lage, ein Gerät auszuwählen und das SSVEP-BCI zu aktivieren. Die ermittelten Zeiten zeigen deutlich, dass ein rein endogenes BCI sich nicht zur direkten Steuerung eines Roboterarmes eignet. Auch konnten nur wenige Probanden alle drei Bewegungsvorstellungen verwenden und wählten daher bewusst nur zwei Bewegungsvorstellungen aus.

Einige Probanden zeigten bei der Auswahl der Geräte eine deutlich schlechtere Leistung als während des Trainings. Als Grund gaben diese die fehlende Rückmeldung während der Bewegungsvorstellungen an. Beim Training erhielten die Probanden eine visuelle Rückmeldung durch das Füllen der Pfeile mit Balken. Diese Art der Rückmeldung wurde im Rahmen des sBCI-Projektes nicht realisiert. Durch eine Veränderung der Lichtintensität von drei LEDs des sBCI-Helms ließe sich eine ähnliche Art der Rückmeldung realisieren.

Im Vergleich zum Stand der Forschung besitzt das SSVEP-BCI eine geringe Genauigkeit und ITR. In der Arbeit [178] wurde mit einem SSVEP-BCI, das über 5 Kommandos verfügt, eine mittlere Genauigkeit von  $96,79 \pm 7,88$  % und eine mittlere ITR von 61,70

$\pm 32,68$  bits/min erreicht. Die Signalverarbeitung ist identisch mit der in dieser Studie verwendeten Signalverarbeitung. Unterschiede bestehen in der Wahl des Zeitfensters, der betrachteten Frequenzen und des verwendeten Stimulators.

Bei den Tests des sBCI-Systemes wurden lediglich die Stimulationsfrequenzen betrachtet. Der Algorithmus der Arbeit [178] betrachtet zusätzlich zu den Stimulationsfrequenzen noch weitere Frequenzen, die zwischen den Stimulationsfrequenzen liegen, um die Stabilität zu verbessern. Dieser Ansatz wurde zur Steuerung des Roboterarmes übernommen und ermöglichte in den Experimenten aus Abschnitt 4.6 eine Verbesserung der Genauigkeit und ITR.

Wie in der Dissertation [110] gezeigt, erlauben die LEDs des sBCI-Helmes keine Verarbeitung von Zeitfenstern unter 1,5 s. Dies resultiert aus der Nähe der LEDs des sBCI-Helmes zueinander sowie des geringen Abstandes der LEDs zu den Augen. Für stabile Ergebnisse wurde das Zeitfenster sogar auf 2 s erhöht. Eine weitere Erhöhung des Zeitfensters würde zwar die Genauigkeit verbessern, jedoch gleichzeitig zu einer Verringerung der ITR führen. In den Experimenten aus Abschnitt 4.6 wurde das Zeitfenster beibehalten und trotzdem eine Erhöhung der Genauigkeit erreicht.

Eine Vergrößerung der LEDs würde eine Überarbeitung des sBCI-Helmes erforderlich machen. In Abschnitt 4.2 wird eine Halterung für LEDs präsentiert, die sich provisorisch mit dem Helm verbinden lässt. Mit dieser Halterung erfolgt in dem genannten Abschnitt ein Vergleich zwischen den LEDs des sBCI-Helmes und deutlich größeren LEDs. Mit den größeren LEDs wurde eine höhere Klassifikationsgenauigkeit erzielt als mit den LEDs des sBCI-Helmes. In den Experimenten aus Abschnitt 4.6 führten die großen LEDs außerdem zu einer größeren ITR.

Die Ergebnisse der ersten Versuche mit dem sBCI-Helm [113] sind deutlich besser, als die in dieser Studie ermittelten Werte. Die mittlere ITR betrug dort 41,2 bits/min und ist somit mehr als doppelt so groß. Da die ITR von einigen Probanden über dem maximal möglichen Wert liegen, sind die Ergebnisse nicht korrekt und können somit nicht für einen Vergleich herangezogen werden.



Aufgrund der großen Anzahl an Kommandos, der sofortigen Einsatzmöglichkeit, der hohen Genauigkeit und der hohen ITR empfiehlt sich der Einsatz von SSVEP als Umschalt- und Steuermodalität für die Roboterarmsteuerung. Ein Einschalten des SSVEP-BCIs und somit der LEDs sollte über eine einzige Bewegungsvorstellung erfolgen. Hierfür kann die vom Probanden am besten vorzustellende Bewegung verwendet werden.



## **Kapitel 4.**

# **Schrittweise Steuerung eines Roboterarmes über ein hybrides BCI**

In diesem Kapitel wird ein System zur schrittweisen Steuerung eines Roboterarmes über ein hybrides BCI vorgestellt. Mit dem in Kapitel 3 beschriebenen hybriden BCI stehen dem Nutzer des Systems vier diskrete Kommandos über die vier LEDs des sBCI-Helmes und drei weitere Kommandos über Bewegungsvorstellungen zur Verfügung. Da die Anzahl der zur Verfügung stehenden Kommandos gering ist, kann immer nur ein Freiheitsgrad des Roboterarmes zur Zeit gesteuert werden. Zum Umschalten zwischen den verschiedenen Steuerungsgruppen und zur Steuerung innerhalb einer Gruppe, wird deshalb ein Zustandsautomat verwendet. Eine Roboterregelung empfängt die Steuerkommandos und führt die diskreten Schritte aus. Über die Detektion von SSVEPs oder P300-Potenzialen lässt sich die Konzentration auf eine LED feststellen. Mit den beiden Paradigmen kann der Nutzer des Systems zwischen den Steuerungsgruppen umschalten und Bewegungen in diskreten Schritten ausführen. Aufgrund der hohen Trainingszeit und der geringen Kommunikationsgeschwindigkeit von Bewegungsvorstellungen, wird nur eine der drei Bewegungsvorstellungen zum Ein- und Ausschalten des visuellen Stimulators verwendet.

Zu Beginn dieses Kapitels werden die Anforderungen an die Roboterarmsteuerung beschrieben und eine Übersicht über das System geliefert. Die Übersicht stellt dar, über

welche Komponenten die Steuerung verfügt und wie die Komponenten zusammenwirken. Anschließend erfolgt eine Beschreibung der beiden Umschalt- und Steuermodalitäten SSVEP und P300. Danach findet eine Beschreibung von zwei Zustandsautomaten statt, die eine Roboterarmsteuerung über ein hybrides BCI ermöglichen. Im Anschluss wird die Implementierung der Regelung des Roboters präsentiert. Nach der Beschreibung der einzelnen Komponenten folgt eine Vergleichsstudie der Umschalt- und Steuermodalitäten und der Zustandsautomaten. Anhand der Studie wird gezeigt, welche Modalität und welcher Zustandsautomat am geeignetsten für eine Roboterarmsteuerung sind. Zum Schluss wird die Steuerung anhand einer Pick-and-Place-Aufgabe getestet und unter objektiven und subjektiven Kriterien evaluiert.

## **4.1. Systemanforderungen und -übersicht**

Das Ziel einer Mensch-Roboter-Schnittstelle (engl. Human-Robot Interface (HRI)) besteht darin, eine Kommunikation zwischen einem Menschen und einem Roboter zu ermöglichen. Mit dem in Kapitel 3 beschriebenen hybriden BCI, das die beiden Paradigmen SSVEP und ERD/ERS nutzt, stehen dem Nutzer einige wenige diskrete Kommandos zur Kommunikation zur Verfügung. Vier Kommandos aufgrund der vier LEDs und drei Kommandos aufgrund von drei Bewegungsvorstellungen. Das in dieser Arbeit zu entwickelnde System muss in der Lage sein, über diese Kommandos den Greifer eines Roboterarmes in jede Position und Orientierung bringen zu können. Viele weitere wichtige Anforderungen müssen bei der Entwicklung einer solchen Schnittstelle berücksichtigt werden. Einige der Hauptanforderungen lauten wie folgt:

1. Das System muss in der Lage sein, aus den EEG-Signalen vierzehn Kommandos für eine Bewegung des Greifers zu erzeugen: sechs Kommandos für eine translatorische Bewegung des Greifers entlang der negativen oder positiven Richtung der x-, y-, oder z-Achse, sechs Kommandos für eine entsprechend rotatorische Bewegung und zwei Kommandos für ein Öffnen und Schließen des Greifers.

2. Ein weiteres Kommando wird für einen Wechsel zwischen dem Basis- und dem Greiferkoordinatensystem benötigt.
3. Die Schrittweite des Greifers muss einstellbar sein.
4. Das System muss eine direkte Interaktion zwischen dem Nutzer und dem Roboter ermöglichen. Eine Steuerung des Roboterarmes darf nicht über eine grafische Nutzerschnittstelle erfolgen, da hierbei eine Störung der visuellen Aufmerksamkeit des Nutzers auftritt. Auch wäre dabei eine Bewegung des Kopfes oder der Augen erforderlich, die jedoch nicht jeder behinderte Mensch willentlich ausführen kann.
5. Die Berechnungen der inversen Kinematik müssen vom System durchgeführt werden, wodurch der Nutzer seine Kommandos in kartesischen Koordinaten senden kann. Hierdurch wird die kognitive Belastung des Nutzers reduziert.
6. Visuelle Stimulationen, die die exogenen BCIs (SSVEP und P300) benötigen, müssen abschaltbar sein. Zur visuellen Stimulation kommen die LEDs des sBCI-Helmes zum Einsatz, welche mit einer konstanten Frequenz blinken oder nach einem zufälligen Muster aufleuchten. Dieses Blinken bzw. Aufleuchten wirkt mit der Zeit ermüdend und belastend auf den Nutzer. Die Deaktivierung der Stimulation kann zwar über die exogenen BCIs erfolgen, eine Aktivierung muss jedoch mittels eines endogenen BCIs (ERD/ERS) möglich sein, welches keine externe Stimulation benötigt.

Eine Übersicht der BCI-basierten Roboterarmsteuerung ist in der Abbildung 4.1 dargestellt. Die Aufnahme und Verarbeitung der EEG-Signale erfolgt mit Hilfe des BCI2000-Frameworks [156]. Dieses nutzt die Programmiersprache C++ und besteht aus vier Modulen: Operator, Signalaufnahme, Signalverarbeitung und Anwendung.

Das Operator-Modul dient als zentrales Relais zur Konfiguration des Systems und zur Visualisierung von Ergebnissen.

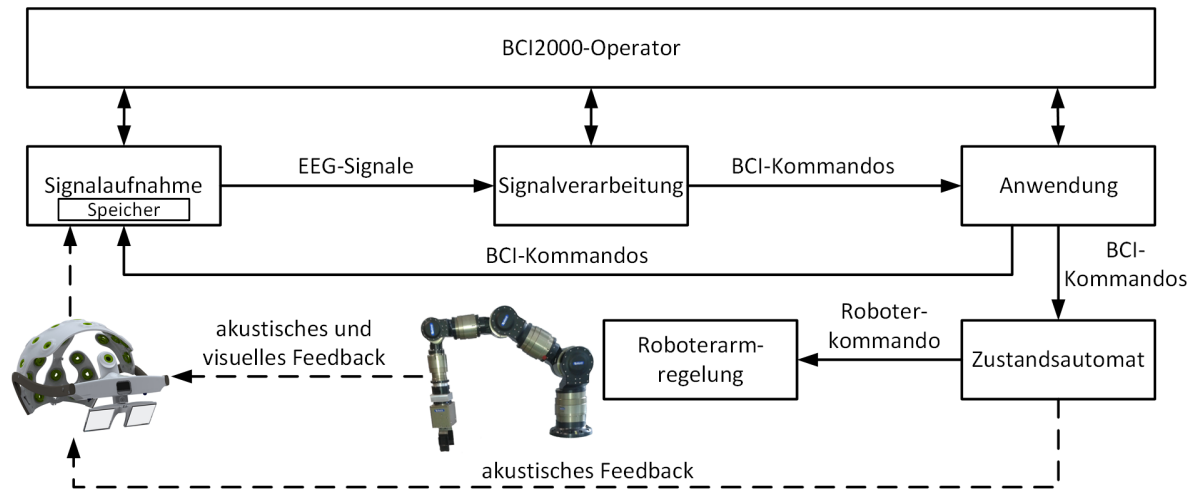


Abbildung 4.1.: Darstellung der BCI-basierten Roboterarmsteuerung.

Die Aufnahme und Filterung der EEG-Signale erfolgt mit dem Signalaufnahmemodul. Zur Reduzierung von Signalversätzen wird ein Hochpassfilter mit einer Grenzfrequenz von 0,1 Hz verwendet. Das Netzrauschen wird mit einem 50 Hz Kerbfilter reduziert. Der Verstärker arbeitet mit einer Abtastfrequenz von 256 Hz und die Signalaufnahme erfolgt in Blöcken von 8 Datenpunkten. Alle 31,25 ms sendet somit das Modul neue Datenpunkte an die Signalverarbeitung. Nach der Signalverarbeitung speichert das Modul die Daten zusammen mit den Klassifikationsergebnissen.

Sobald neue Datenpunkte beim Signalverarbeitungsmodul ankommen, speichert dieses die gelieferten Daten in einem zwei Sekunden umfassenden FIFO-Puffer. Anschließend erfolgt die Verarbeitung des Puffers. Neben der Signalverarbeitung in C++ ist auch eine Verarbeitung in Matlab möglich. Für alle Algorithmen dieser Dissertation existieren Implementierungen in beiden Programmiersprachen. Der in Abschnitt 3.2.2 beschriebene Algorithmus dient der Detektion von Bewegungsvorstellungen. Über die Detektion von SSVEPs und P300-Potenzialen kann die Signalverarbeitung feststellen, auf welche der vier LEDs der Nutzer seine Konzentration richtet. Die beiden nachfolgenden Abschnitte befassen sich ausführlich mit der Signalverarbeitung der beiden BCI-Paradigmen SSVEP und P300. Aufgrund der kontinuierlichen Verarbeitung der Signale und der Einführung

eines Nichtkontrollzustandes, operiert das System asynchron. Der Nutzer ist somit in der Lage, zu selbst bestimmten Zeitpunkten ein Kontrollkommando zu senden.

Die Signalverarbeitung übermittelt die Klassifikationsergebnisse an das Anwendungsmodul, welches die Ergebnisse lediglich an eine externe Anwendung weiterleitet. Die Kommunikation zwischen BCI2000 und der externen Anwendung erfolgt über das UDP-Netzwerkprotokoll in Echtzeit. Bei der externen Anwendung handelt es sich um den in C++ implementierten Zustandsautomaten zur schrittweisen Steuerung eines Roboterarmes. Eine Bewegungsvorstellung ermöglicht die Aktivierung und Deaktivierung des visuellen Stimulators des sBCI-Helmes. Die Kommandos der vier LEDs dienen zum Umschalten zwischen den verschiedenen Steuerungsgruppen des Roboterarmes und zur Steuerung der ausgewählten Gruppe. Nach jedem verarbeiteten Kommando folgt eine Ruhephase von zwei Sekunden, damit der Anwender Gelegenheit erhält, seine Konzentration von einer LED abzuwenden oder eine Bewegungsvorstellung zu beenden. Ansonsten könnte es passieren, dass ein Kommando ungewollt mehrfach hintereinander detektiert wird. Ebenfalls über das UDP-Netzwerkprotokoll übermittelt der Zustandsautomat die diskreten Roboterkommandos an die Regelung des Roboterarmes. Das mit dem Robot Operating System (ROS)-Framework implementierte Programm sorgt für die Ausführung der geforderten Bewegung.

## 4.2. SSVEPs als Umschalt- und Steuermodalität

Dieser Abschnitt beschreibt das SSVEP-BCI, welches zur Roboterarmsteuerung verwendet wird. Das SSVEP-BCI verfügt über vier LEDs und stellt dem Anwender der Roboterarmsteuerung somit vier Kommandos bereit. Mit Hilfe dieser Kommandos kann der Nutzer zwischen den Steuerungsgruppen des Roboters umschalten und ihn in der ausgewählten Gruppe steuern. Das SSVEP-BCI lässt sich sowohl frequenz- als auch phasenbasiert betreiben. Bei dem frequenzbasierten Ansatz blinken die LEDs mit vier

verschiedenen Frequenzen. Wohingegen bei dem phasenbasierten Ansatz alle LEDs mit derselben Frequenz aber mit unterschiedlichen Phasen blinken.

Zu Beginn dieses Abschnittes werden die zur Erzeugung von SSVEPs verwendeten Stimuli vorgestellt. Anschließend erfolgt eine Beschreibung der Signalverarbeitung, die eine Detektion der Stimulationsfrequenz und der Phaseninformation ermöglicht. Zum Schluss wird die Kalibrierung beschrieben, die die optimalen Stimulationsfrequenzen für einen Probanden ermittelt. Anhand der Kalibrierungsergebnisse von 11 Probanden wird gezeigt, welche Parameter für die Signalverarbeitung zu wählen sind.

#### **4.2.1. Stimulus**

Zur Erzeugung von SSVEPs muss der Mensch seine Konzentration auf einen visuellen Stimulus richten. In dieser Arbeit wird hierfür der visuelle Stimulator des sBCI-Helms verwendet, welcher über vier LEDs, im peripheren Sichtfeld des Nutzers, verfügt. Eine Beschreibung des Stimulators lässt sich dem Abschnitt 3.1 entnehmen. Bei einem frequenzbasierten SSVEP-BCI blinken alle LEDs mit einer anderen Frequenz. Hingegen nutzt ein phasenbasiertes SSVEP-BCI für alle LEDs dieselbe Frequenz, welche zur Unterscheidung jedoch phasenverschoben präsentiert wird. Die Zuordnung der Frequenzen und Phasen zu den vier LEDs sowie die verwendeten Blinksequenzen sind der Abbildung 4.2 zu entnehmen. Die Einstellung der Stimulationsfrequenzen und der Phasen erfolgt über den in Abschnitt 3.1 beschriebenen Mustergenerator.

Bei dem in Abschnitt 3.3 beschriebenen Test des sBCI-Systems wurden die Genauigkeiten und ITR für ein SSVEP-basiertes BCI ermittelt. Die in diesem Versuch ermittelten Werte liegen unterhalb derer aus der Literatur. Um festzustellen, ob die Verwendung größerer LEDs, als die im Helm integrierten LEDs, zu einer Steigerung der Leistung des SSVEP-BCIs führt, wurde eine Halterung für vier große LEDs entwickelt, die sich am Helm provisorisch befestigen lässt. Jede der vier LEDs besitzt eine Größe von  $2 \times 2$  cm und befindet sich, wie die LEDs des Helms, im peripheren Sichtfeld des Nutzers. Der Abstand zu den Augen beträgt ca. 11 cm.



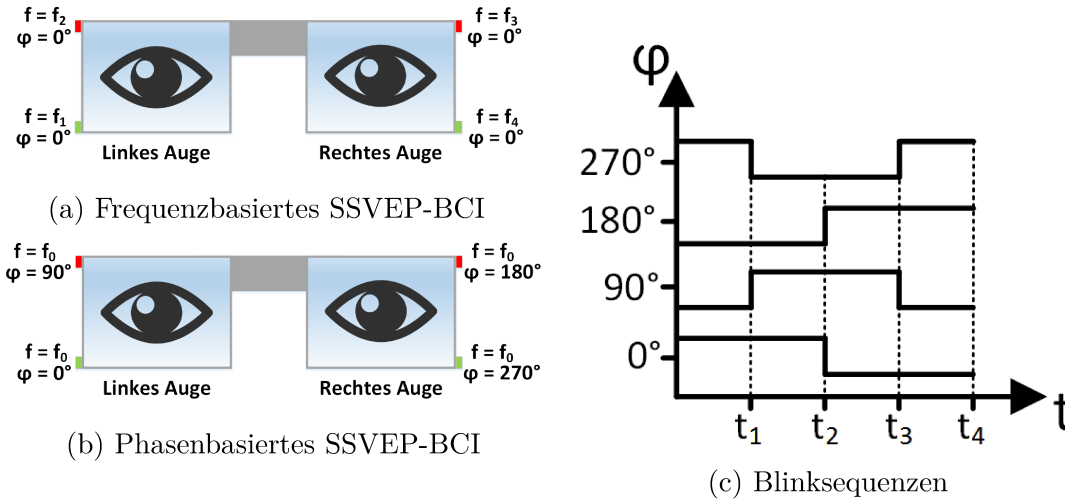


Abbildung 4.2.: Zuordnung der Frequenzen und Phasen zu den vier LEDs des sBCI-Helmes bei einem frequenz- (a) und phasenbasiertem (b) SSVEP-BCI sowie die Darstellung der verwendeten Blinksequenzen (c).

#### 4.2.2. Signalverarbeitung

In diesem Abschnitt wird die Signalverarbeitung zur Detektion der Stimulationsfrequenzen und der Phaseninformation erläutert. Die Signalverarbeitung des frequenzbasierten SSVEP-BCIs ist identisch mit dem unter Abschnitt 3.2.1 beschriebenen Algorithmus des sBCI-Systems. Dieser Algorithmus verwendet die MEC-Methode zur Berechnung der räumlichen Filter. Eine Alternative bietet die in der Arbeit [57] beschriebene Maximum-Contrast-Combination (MCC)-Methode, welche in diesem Abschnitt beschrieben wird. Das phasenbasierte SSVEP-BCI nutzt denselben Algorithmus wie das frequenzbasierte SSVEP-BCI zur Berechnung der Wahrscheinlichkeit einer Stimulationsfrequenz. Zusätzlich benötigt es die in einer Kalibrierungssitzung aufgenommenen Daten zum Training eines weiteren räumlichen Filters und des Klassifikators. Der räumliche Filter wird mit der MCC-Methode berechnet und liefert den Kanal zur Berechnung der Phase. Die Berechnung der Phase erfolgt über die Hilbert-Transformation, welche die Blinksequenz einer LED als Referenzsignal benötigt. Zur Klassifikation der Frequenz- und Phaseninformation wird eine SVM und die LDA verwendet.

#### 4.2.2.1. Signalvorverarbeitung

Wie bereits in Abschnitt 3.2.1.2 beschrieben, erfolgt die räumliche Filterung der Signale wie folgt:

$$\mathbf{S} = \mathbf{Y}\mathbf{W}. \quad (4.1)$$

Die Matrix  $\mathbf{Y} \in \mathbb{R}^{N_t \times N_y}$  beinhaltet die Signale von  $N_y$  Elektroden, die aus jeweils  $N_t$  Datenpunkten bestehen. Der räumliche Filter  $\mathbf{W} \in \mathbb{R}^{N_y \times N_s}$  ermöglicht die Erstellung von  $N_s$  Kanälen, die eine lineare Kombination der Elektrodensignale darstellen.

Neben der in Abschnitt 3.2.1.2 beschriebenen MEC-Methode, gibt es noch weitere Methoden zur Berechnung der Filterkoeffizienten. In der Arbeit [57] lieferte die MCC-Methode sehr gute Ergebnisse und wird daher zum Vergleich bei der Auswertung der Kalibrierungsdaten in Abschnitt 4.2.3 herangezogen und im Folgenden beschrieben.

Mit der MCC-Methode wird die Energie der SSVEP-Frequenzen maximiert und gleichzeitig die Energie in den Störsignalen minimiert. Dies wird unter Verwendung folgender Gleichung erreicht [57]:

$$\max_{\hat{\mathbf{w}}} \frac{\|\mathbf{Y}\hat{\mathbf{w}}\|^2}{\|\tilde{\mathbf{Y}}\hat{\mathbf{w}}\|^2} = \max_{\hat{\mathbf{w}}} \frac{\hat{\mathbf{w}}^T \mathbf{Y}^T \mathbf{Y} \hat{\mathbf{w}}}{\hat{\mathbf{w}}^T \tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}} \hat{\mathbf{w}}}. \quad (4.2)$$

Dies ist der sogenannte Rayleigh-Quotient, dessen Maxima durch die Lösung des verallgemeinerten Eigenwertproblems der Matrizen  $\mathbf{Y}^T \mathbf{Y}$  und  $\tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}$  gefunden werden können. Die Matrix  $\tilde{\mathbf{Y}}$  enthält annähernd nur noch die Stör- und Rauschsignale und wird durch Projektion der Signale  $\mathbf{Y}$  auf das orthogonale Komplement der Modellmatrix  $\mathbf{X} \in \mathbb{R}^{N_t \times 2N_h}$  berechnet:

$$\tilde{\mathbf{Y}} = \mathbf{Y} - \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (4.3)$$

mit

$$\mathbf{X} = [\mathbf{X}_1 \dots \mathbf{X}_{N_h}]. \quad (4.4)$$

Jede Untermatrix  $\mathbf{X}_k \in \mathbb{R}^{N_t \times 2}$  besitzt eine Sinus- und Kosinuskomponente mit der harmonischen Frequenz  $kf$  als Spaltenvektor. Der Parameter  $N_h$  steht für die betrachtete Anzahl an harmonischen Frequenzen. Die Eigenvektoren liefern die Positionen der lokalen Maxima und die Eigenwerte bestimmen die Werte des Quotienten an diesen Maxima. Alle Eigenwerte sind größer oder gleich eins. Ein Eigenwert von 1,2 bedeutet z.B., dass die Energie in den SSVEP-Frequenzen 20 % größer ist als die Energie in den Nicht-SSVEP-Frequenzen. Je größer der Eigenwert, umso größer ist der Signalrauschabstand innerhalb des mit dem dazugehörigen Eigenvektor erstellten Kanals. Daher empfiehlt sich die Verwendung der Eigenvektoren  $(\mathbf{v}_1, \dots, \mathbf{v}_{N_s})$  mit den absteigend sortierten  $N_s$  größten Eigenwerten  $(\lambda_1, \dots, \lambda_{N_s})$  zur Erstellung der Gewichtungsmatrix  $\mathbf{W}$ .

Der in der Arbeit [57] beschriebene Algorithmus nutzt nur die Eigenvektoren, die Kanäle produzieren, in denen die Energie pro Dimension im SSVEP-Unterraum größer ist als die Energie pro Dimension im Rest des Signals. Demnach müsste der Algorithmus alle Eigenvektoren verwenden, deren Eigenwerte größer als eins sind. Stattdessen verwendet er alle Eigenvektoren, deren Eigenwerte größer als  $N_t/(N_t - 2N_h)$  sind. Bei der in Abschnitt 4.2.3 beschriebenen Auswertung der Kalibrierungsdaten hat sich jedoch gezeigt, dass nach dieser Regel zu viele Störsignale erhalten bleiben. Daher wird, in Anlehnung an den Ansatz der MEC-Methode, die Anzahl an gefilterten Kanälen  $N_s$  auf den kleinsten Wert gesetzt, für den gilt:

$$\frac{\sum_{i=1}^{N_s} (\lambda_i - 1)}{\sum_{j=1}^{N_y} (\lambda_j - 1)} > 0,9. \quad (4.5)$$

#### 4.2.2.2. Merkmalsextraktion

Die Merkmale zur Klassifikation der Stimulationsfrequenz sind dieselben, wie beim sBCI-System aus dem vorherigen Kapitel. Wie bereits in Abschnitt 3.2.1.3 beschrieben, wird zuerst für jede Frequenz die Signalenergie berechnet und diese Werte werden anschließend zu Wahrscheinlichkeiten konvertiert. Das phasenbasierte SSVEP-BCI benötigt zusätzlich noch die Phaseninformation, um zwischen den Stimulanzen zu unterscheiden.

Anstatt die Phase für jeden Kanal einzeln zu bestimmen, erfolgt die Berechnung anhand eines einzigen räumlich gefilterten Kanals. Wie in der Arbeit [194] gezeigt, eignet sich zur Berechnung des Filters die MCC-Methode. Mittels zuvor aufgenommener Trainingsdaten wird der räumliche Filter erstellt. Der Eigenvektor mit dem größten Eigenwert bildet den räumlichen Filter.

Die Hilbert-Transformation ermöglicht die Berechnung der Phasendifferenz zwischen dem Referenzsignal  $l(t)$  und dem gefilterten Signal  $s(t)$  an der Stimulationsfrequenz. Bei dem Referenzsignal handelt es sich um die aufgenommene Blinksequenz einer LED. In dieser Arbeit wird die LED mit der Phase  $0^\circ$  verwendet. Die Hilbert-Transformation der beiden Signale erfolgt wie folgt [101]:

$$s_h(t) = \int_{-\infty}^{+\infty} s(\tau)h(t - \tau)d\tau, \quad (4.6)$$

$$l_h(t) = \int_{-\infty}^{+\infty} l(\tau)h(t - \tau)d\tau. \quad (4.7)$$

Sie lässt sich somit als Faltung eines Signals mit der Funktion  $h(t) = 1/\pi t$  betrachten. Lediglich, wenn  $s(t)$  und  $l(t)$  Schmalband-Signale sind, besitzt die Phase eine physikalische Bedeutung. Daher ist eine vorherige Bandpassfilterung der beiden Signale notwendig. Hierfür wird ein Filter mit endlicher Impulsantwort (engl. Finite Impulse Response (FIR)) und einer Bandbreite von 1 Hz, die zentriert über der Stimulationsfrequenz liegt, verwendet.

Nach der Hilbert-Transformation erfolgt die Bildung folgender analytischer Signale [123]:

$$S(t) = s(t) + j \cdot s_h(t) = A_s(t)e^{j\varphi_s(t)}, \quad (4.8)$$

$$L(t) = l(t) + j \cdot l_h(t) = A_l(t)e^{j\varphi_l(t)} \quad (4.9)$$

mit den durch einen Bandpass gefilterten Signalen  $s(t)$  und  $l(t)$  als Realteil und den Hilbert-transformierten Signalen  $s_h(t)$  und  $l_h(t)$  als Imaginärteil.

Die Phasendifferenz, zwischen den beiden Signalen zum Zeitpunkt  $t$ , ist wie folgt definiert [170]:

$$\begin{aligned}\Delta\varphi_{ls}(t) &= \varphi_l(t) - \varphi_s(t) \\ &= \arctan\left(\frac{s(t)l_h(t) - l(t)s_h(t)}{l(t)s(t) + l_h(t)s_h(t)}\right).\end{aligned}\tag{4.10}$$

Innerhalb eines Zeitfensters wird die Phase  $\varphi$  als der Median von  $\Delta\varphi_{ls}(t)$  gewählt.

#### 4.2.2.3. Klassifikation

Das frequenzbasierte SSVEP-BCI nutzt zur Klassifikation ein Verfahren basierend auf Schwellwerten. Wie bereits beim sBCI-System in Abschnitt 3.2.1.4 beschrieben, muss für ihre Detektion eine Frequenz die maximale Wahrscheinlichkeit besitzen, einen vorher definierten Schwellwert überschreiten und eine Stimulationsfrequenz sein. Zur Erhöhung der Robustheit betrachtet der Algorithmus zusätzlich zu den Stimulationsfrequenzen weitere Frequenzen. Neben den Stimulationsfrequenzen ist der Klassifikator in der Lage, den Ruhezustand zu klassifizieren. Der Vorteil des schwellwertbasierten Klassifikators besteht darin, dass keine vorherige Kalibrierung notwendig ist. Ein weiterer Vorteil besteht darin, dass es sich bei den verwendeten Schwellwerten um relative Wahrscheinlichkeiten und nicht um absolute Werte handelt. Somit sind die Schwellwerte unabhängig von der Länge des betrachteten Zeitfensters. Die Bestimmung der Schwellwerte erfolgt empirisch vor der eigentlichen Nutzung des Systems.

Beim phasenbasierten SSVEP-BCI ermöglicht die Betrachtung zusätzlicher Frequenzen die Verwendung von Wahrscheinlichkeiten, obwohl nur eine Stimulationsfrequenz vorliegt. Auch hier kann die Klassifikation anhand von Schwellwerten erfolgen. In diesem Fall wird in einem ersten Schritt festgestellt, ob die Wahrscheinlichkeit der Stimulationsfrequenz über einem Schwellwert liegt. Ist dies der Fall, so wird anschließend ermittelt, in welchem Bereich die Phase liegt. Um den Prozess der Auswahl von Schwellwerten zu vereinfachen, und da zur Erstellung des räumlichen Filters für die Phasenberechnung

ohnehin Kalibrierungsdaten notwendig sind, kommen zur Klassifikation Methoden des maschinellen Lernens zum Einsatz. Im Rahmen der Auswertung von Kalibrierungsdaten im nachfolgenden Abschnitt 4.2.3 werden entweder eine SVM mit der Gaußschen RBF als Kernel oder die LDA eingesetzt. Beide Klassifikatoren finden am häufigsten in der BCI-Forschung Verwendung [15]. Da die Phase ein periodischer Wert ist, findet vor der Klassifikation eine Konvertierung der Merkmale von Polarkoordinaten in kartesische Koordinaten statt:

$$x = p' \cos(\varphi), \quad (4.11)$$

$$y = p' \sin(\varphi) \quad (4.12)$$

wobei  $p'$  die Wahrscheinlichkeit und  $\varphi$  die Phase der Stimulationsfrequenz ist.

### 4.2.3. Kalibrierung

In diesem Abschnitt wird die Kalibrierung zur Ermittlung der optimalen nutzerspezifischen Stimulationsfrequenzen beschrieben. Anhand der Kalibrierungsdaten von 11 Probanden wird ermittelt, welche Parameter für die Signalverarbeitung zu wählen sind.

Zur Kalibrierung wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Über die im Rahmen dieser Arbeit entwickelte Anwendung wird der Ablauf der Kalibrierung gesteuert. In einer Sequenz blinken die vier LEDs mit der gleichen Frequenz, jedoch immer um  $90^\circ$  phasenverschoben. Die Anwendung fordert den Probanden akustisch und visuell dazu auf, seine Konzentration auf eine der LEDs zu richten oder abzuwenden. Der Operator ermöglicht die Einstellung der zu kalibrierenden Frequenzen, der Blinkdauer der LEDs (Stimulus-Intervall) und der Ruhephase zwischen zwei Stimulationen (ISI).

#### 4.2.3.1. Versuchsteilnehmer

Insgesamt wurden Kalibrierungsdaten von 11 Probanden aufgenommen. Die Gruppe bestand aus 6 Frauen und 5 Männern. Das Alter der Probanden lag zwischen 23 und 32 Jahren, mit einem Durchschnittsalter von  $26,82 \pm 2,93$  Jahren. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### 4.2.3.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Zur visuellen Stimulation wurden in einem ersten Durchlauf die im Helm integrierten LEDs verwendet. In einem weiteren Durchlauf erfolgte die Stimulation über die in Abschnitt 4.2.1 beschriebenen größeren LEDs, die über eine Halterung mit dem Helm verbunden waren. Zur Aufnahme der EEG-Signale wurden 8 Kanäle ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex verwendet. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter  $5\text{ k}\Omega$  gebracht. Die Aufnahme der Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Als Referenzsignal wurde die Blinksequenz der unteren linken LED mit der Phase  $0^\circ$  aufgenommen. Hierfür wurde der 5 V Ausgang des LED-Mustergenerators mit dem Digitaleingang des Verstärkers verbunden.




Abbildung 4.3.: Zeitlicher Ablauf der SSVEP-Kalibrierung. Innerhalb der Stimulus-Phase richtet der Proband seine Konzentration auf die angegebene LED. Nach dieser Phase folgt eine Ruhepause (ISI). Der Wechsel von Stimulus Phase und ISI wird so oft wiederholt, bis jede LED einmal betrachtet wurde. Nach einer Sequenz wird entweder eine andere Stimulationsfrequenz verwendet oder die Kalibrierung endet.

Bis auf das Referenzsignal erfolgte eine Filterung der Signale mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz).

#### 4.2.3.3. Versuchsprotokoll

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte zwei Stunden inklusive Erläuterung der Aufgabenstellung, Präparieren des sBCI-Helmes und dem Waschen der Haare. Für jeden Probanden wurden Daten für Stimulationsfrequenzen von 10 bis 39 Hz, in ganzzahligen Frequenzschritten, aufgenommen. In einem Kalibrierungsdurchlauf wurden die Probanden mit 5 Frequenzen hintereinander stimuliert. Zwischen den Durchläufen erhielten die Probanden die Möglichkeit für eine Ruhepause. Jede der genannten Frequenzen wurde in einer einzigen Sequenz zur Stimulation benutzt. Die gesamte Kalibrierungsprozedur fand zuerst unter Verwendung der LEDs des sBCI-Helmes statt und nach einer längeren Ruhepause unter Verwendung der großen LEDs aus Abschnitt 4.2.1.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist in der Abbildung 4.3 zu sehen. Alle vier LEDs blinken innerhalb einer Sequenz mit derselben Frequenz, aber mit unterschiedlichen Phasen. In der Pre-Run-Phase erhält der Proband für 5 s Gelegenheit,



sich auf den Durchlauf einzustellen. Zu Beginn der Stimulus-Phase wird der Proband akustisch und visuell dazu aufgefordert, seine Konzentration auf eine der vier LEDs zu richten. Innerhalb der 5 s andauernden Stimulus-Phase sollte der Proband ein Blinzeln der Augen vermeiden. Nach dieser Phase folgt das ISI von 5 s. In dieser Phase darf der Proband seine Konzentration auf keine der LEDs richten und erhält die Gelegenheit zu blinzeln. Der Wechsel von Stimulus-Phase und ISI wird so oft wiederholt, bis jede LED einmal betrachtet wurde. Nach einer Sequenz wird entweder eine andere Stimulationsfrequenz verwendet oder die Kalibrierung endet. Sowohl die Festlegung der Sequenzen der Stimulationsfrequenzen als auch die der Reihenfolge der LEDs erfolgt über einen Zufallsgenerator.

### 4.2.3.4. Evaluierung

Die Evaluierung der aufgenommenen Daten erfolgte, für jeden Probanden und jede Frequenz einzeln, in Matlab mit einer  $10 \times 6$ -fachen stratifizierten Kreuzvalidierung. Hierzu wurden die Daten der vier Kontrollzustände ( $90^\circ$ ,  $180^\circ$ ,  $270^\circ$  und  $360^\circ$ ) und des Nichtkontrollzustandes (NC) extrahiert. Während eines Kontrollzustandes richtete der Proband seine Konzentration auf eine der vier LEDs und wendete seine Konzentration während des Nichtkontrollzustandes ab. Die Extraktion der Daten erfolgte alle 125 ms mit einem Zeitfenster von 2 s. Als Merkmale dienten die Wahrscheinlichkeit und die Phaseninformation. Mit Hilfe des phasenbasierten Algorithmus aus Abschnitt 4.2.2 wurden die Merkmale für jedes Datensegment berechnet. Um die Wahrscheinlichkeit für die Stimulationsfrequenz zu erhalten, wurden 8 weitere Frequenzen bei der Signalverarbeitung betrachtet. Diese lagen in Schritten von 0,5 Hz um die Stimulationsfrequenz. Zur Berechnung der Phase wurden in einer Auswertung der Kanal  $O_z$  und in einer weiteren Auswertung der erste räumlich gefilterte Kanal verwendet. Der räumliche Filter zur Phasenberechnung wurde mittels der Trainingsdaten und der MCC-Methode berechnet. Die Berechnung der räumlichen Filter für die Berechnung der Stimulationsfrequenzen erfolgte einmal mit der MCC-Methode und ein weiteres Mal mit der MEC-Methode.

Betrachtet wurden entweder nur die erste oder die erste und die zweite Harmonische. Zur Klassifikation wurden in einem Durchlauf die LDA und in einem weiteren Durchlauf eine SVM, mit einer RBF als Kernel, eingesetzt.

Die Abbildung 4.4 zeigt die Wahrscheinlichkeiten und Phasen für einen Probanden, der mit einer Frequenz von 24 Hz stimuliert wurde. In dem Polardiagramm sind die Wahrscheinlichkeiten als Radius und die Phasen als Winkel eingezeichnet. Bei diesem Probanden liefern sowohl die großen LEDs als auch die MCC-Methode die besten Ergebnisse. Die Stimulation mit den großen LEDs führte zu einem gleichmäßigeren Phasenabstand zwischen den Kontrollzuständen und zu einem größeren Abstand zwischen den Kontrollzuständen und dem Nichtkontrollzustand als die Stimulation mit den LEDs des sBCI-Helmes. Ebenfalls zu einem größeren Abstand zwischen den Kontrollzuständen und dem Nichtkontrollzustand führte die MCC-Methode im Vergleich zur MEC-Methode.

Eine Gegenüberstellung der beiden Klassifikatoren zeigt die Abbildung 4.5. Zu sehen sind die extrahierten Merkmale und die Klassenregionen in kartesischen Koordinaten. Der Filter wurde mit der MCC-Methode berechnet und die Stimulation erfolgte mit den großen LEDs. Die Stimulationsfrequenz des Probanden betrug 24 Hz. Die SVM liefert für diesen Probanden das beste Ergebnis, da die Region des Nichtkontrollzustandes annähernd einen Kreis darstellt und sich somit die Wahrscheinlichkeit als Radius in den Ergebnissen widerspiegelt. Bei der Wahl der Parameter muss darauf geachtet werden, dass es zu keiner Überanpassung (engl. overfitting) des Klassifikators kommt. In diesem Beispiel ist bei der SVM die Region der Klasse  $90^\circ$  zu nahe an den Beobachtungen des Nichtkontrollzustandes. Dies kann zu einem fehlerhaften Senden des Kontrollkommandos führen.

Um aussagekräftigere Ergebnisse zu erhalten, wurden die Klassifikationsgenauigkeiten für jeden Probanden, jede Stimulationsfrequenz und jeden Parameter ermittelt.

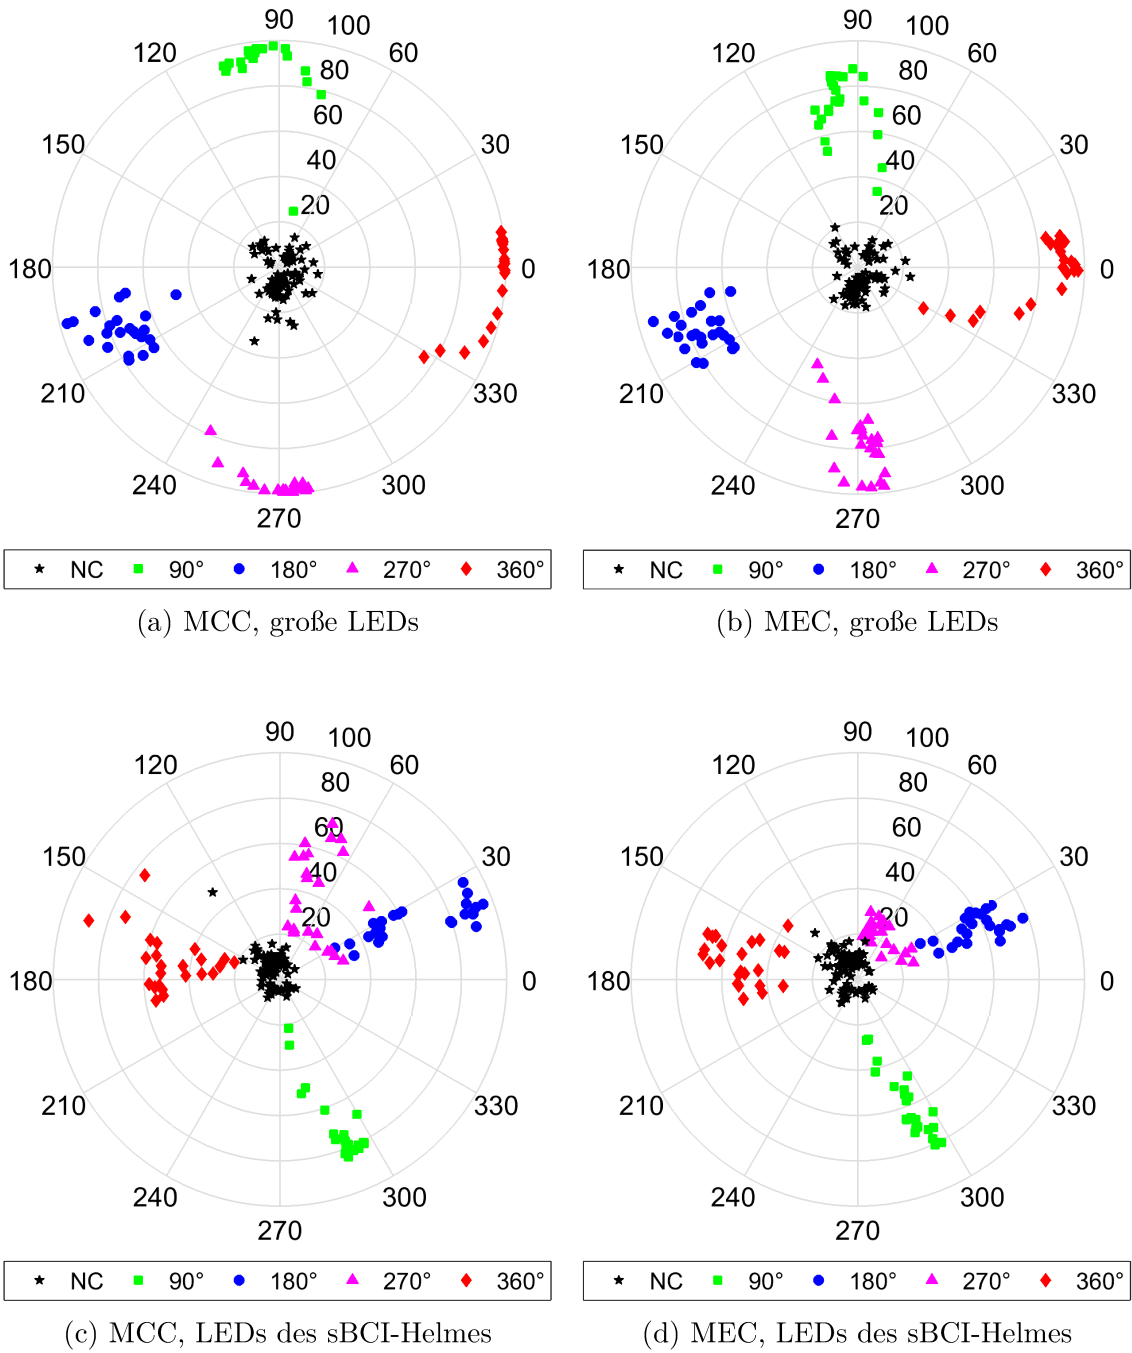


Abbildung 4.4.: Darstellung der berechneten Wahrscheinlichkeiten und Phasen für eine Stimulationsfrequenz von 24 Hz in Polarkoordinaten. Die Wahrscheinlichkeiten sind als Radius und die Phasen als Winkel eingezeichnet.

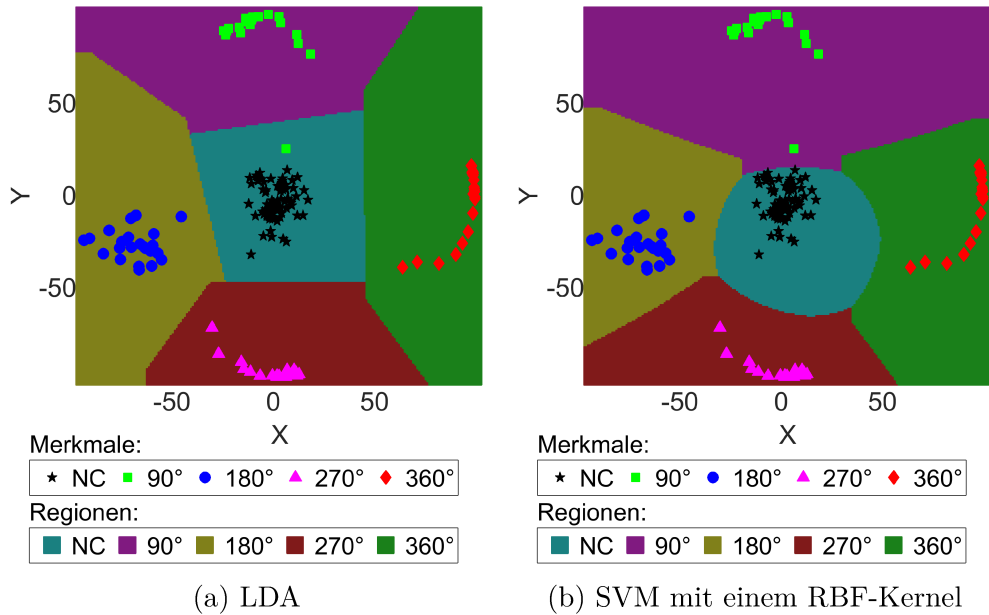


Abbildung 4.5.: Darstellung der berechneten Merkmale und Klassenregionen für eine Stimulationsfrequenz von 24 Hz in kartesischen Koordinaten.

Die Abbildung 4.6 zeigt die Verteilungen der ermittelten Genauigkeiten für verschiedene Parameter. Den Verteilungen liegen die Genauigkeiten von jedem Probanden und jeder Frequenz zugrunde. Für jeden Probanden und jede Frequenz wurde die höchste Genauigkeit für den zu betrachtenden Parameter ausgewählt. Zum Vergleich der Parameter wurde ein Zweistichproben-t-Test für abhängige Stichproben mit einem Signifikanzniveau von 5 % verwendet. Die räumliche Filterung mit der MCC-Methode liefert signifikant höhere Genauigkeiten im Vergleich zur MEC-Methode. Bei der MCC-Methode liegen 75 % der berechneten Genauigkeiten zwischen 85,49 und 100,00 % und bei der MEC-Methode zwischen 80,17 und 100,00 %. Im Mittel liefert die MCC-Methode eine Genauigkeit von  $90,70 \pm 9,27$  % und die MEC-Methode von  $87,70 \pm 9,85$  %. Die Anzahl an Harmonischen und der verwendete Kanal zur Berechnung der Phase besitzen keinen signifikanten Einfluss auf die Genauigkeit. Bei der Verwendung von zwei Harmonischen und des ersten gefilterten räumlichen Kanals sind die Ergebnisse nur gering besser als bei einer Harmonischen und des Kanals  $O_z$ . Der SVM-Klassifikator liefert signifikant bessere Ergebnisse als der LDA-Klassifikator. Von den berechneten Genauigkeiten lie-




Abbildung 4.6.: Verteilungen der Klassifikationsgenauigkeiten für verschiedene Parameter bei der Verwendung eines phasenbasierten SSVEP-BCIs mit vier Kontrollzuständen und einem Nichtkontrollzustand. Den Verteilungen liegen die höchsten Genauigkeiten von jedem Probanden und jeder Frequenz zugrunde.

gen 75 % zwischen 85,65 und 100,00 % beim SVM-Klassifikator und zwischen 82,38 und 100,00 % beim LDA-Klassifikator. Die mittlere Genauigkeit des SVM-Klassifikators liegt bei  $90,93 \pm 9,21$  % und die des LDA-Klassifikators bei  $88,11 \pm 9,38$  %. Weiterhin erzielen die Probanden mit den großen LEDs signifikant höhere Genauigkeiten als mit den LEDs des sBCI-Helmes. Bei den großen LEDs liegen 75 % der Genauigkeiten zwischen 83,63 und 100,00 % und bei den LEDs des Helmes zwischen 78,18 und 99,38 %. Die mittlere Genauigkeit der großen LEDs liegt bei  $89,22 \pm 11,02$  % und die der LEDs des Helmes bei  $85,20 \pm 9,69$  %.

Eine Übersicht über die Verteilungen der Genauigkeiten für Stimulationsfrequenzen von 10 bis 39 Hz liefert die Abbildung 4.7. Den Verteilungen liegen die Genauigkeiten von jedem Probanden zugrunde. Für jeden Probanden wurde die höchste Genauigkeit für die zu betrachtende Frequenz ausgewählt. Wie in dem Diagramm zu sehen, liefern Frequenzen zwischen 14 und 27 Hz die besten Ergebnisse. Fast alle berechneten Genau-




Abbildung 4.7.: Verteilungen der Genauigkeiten für Stimulationsfrequenzen von 10 bis 39 Hz bei der Verwendung eines phasenbasierten SSVEP-BCIs mit vier Kontrollzuständen und einem Nichtkontrollzustand. Den Verteilungen liegen die höchsten Genauigkeiten von jedem Probanden zugrunde.

igkeiten dieser Frequenzen liegen über 90 %. Die Frequenzen im niedrigen und im hohen Frequenzbereich liefern zwar für einzelne Probanden hohe Genauigkeiten, jedoch verringern sich die Genauigkeiten insgesamt sowohl mit sinkender als auch mit steigender Frequenz. Anhand der ermittelten Genauigkeiten eines Probanden können die für den Nutzer optimalen Stimulationsfrequenzen ausgewählt werden.

Zusammenfassend lässt sich feststellen, dass zur räumlichen Filterung die MCC-Methode, zur Klassifikation eine SVM und zur Stimulation die großen LEDs die besten Ergebnisse liefern. Mit dieser Konfiguration wurde das phasenbasierte SSVEP-BCI zur Navigation in einem Zustandsautomaten, der zur Roboterarmsteuerung benötigt wird, eingesetzt und evaluiert. Zusätzlich wurde noch das frequenzbasierte SSVEP-BCI unter Verwendung beider Stimulatoren getestet. Dieses System nutzte jedoch einen schwellwertbasierten Klassifikator. Die Ergebnisse dieser Studie befinden sich in Abschnitt 4.6.

## 4.3. P300-Potenziale als Umschalt- und Steuermodalität

Dieser Abschnitt beschreibt das P300-BCI, welches anstelle des im vorherigen Abschnitt beschriebenen SSVEP-BCIs zur Roboterarmsteuerung verwendet werden kann. Das P300-BCI verfügt über vier LEDs und stellt dem Anwender der Roboterarmsteuerung somit vier Kommandos bereit. Mit Hilfe dieser Kommandos kann der Nutzer zwischen den Steuerungsgruppen des Roboters umschalten und ihn in der ausgewählten Gruppe steuern.

Zu Beginn dieses Abschnittes wird beschrieben, wie die vier LEDs des sBCI-Helmes eine Evokation von P300-Potenzialen bewirken. Anschließend erfolgt eine Beschreibung der Signalverarbeitung, die eine Detektion der P300-Potenziale ermöglicht. Zum Schluss wird die Kalibrierung des P300-BCIs beschrieben. Diese nimmt für jeden Probanden Daten zum Training des verwendeten Klassifikators auf. Anhand der Kalibrierungsergebnisse von 10 Probanden wird gezeigt, wie viele Intensivierungen pro Stimulus notwendig sind, um eine hohe Klassifikationsgenauigkeit zu erzielen.

### 4.3.1. Stimulus

Zur Evokation der P300-Potenziale wird der visuelle Stimulator des sBCI-Helmes verwendet. Dieser verfügt über vier LEDs im peripheren Sichtfeld des Nutzers. Eine Beschreibung des Stimulators lässt sich dem Abschnitt 3.1 entnehmen. Zur Generierung der zufälligen Sequenzen wird der P300-Speller des BCI2000-Frameworks [156] verwendet. Dieser wurde um eine Klasse für die Stimulation über LEDs erweitert. Wie in der Abbildung 4.8a zu sehen, besitzt die Matrix des P300-Spellers eine Größe von  $2 \times 2$ . Da die LEDs des Helmes ebenfalls in Matrixform angeordnet sind, lässt sich jedem Zeichen der P300-Matrix eine LED zuordnen (siehe Abbildung 4.8b). Wird eine Zeile oder Spalte innerhalb der P300-Matrix intensiviert, leuchten die entsprechenden LEDs des Helmes auf.

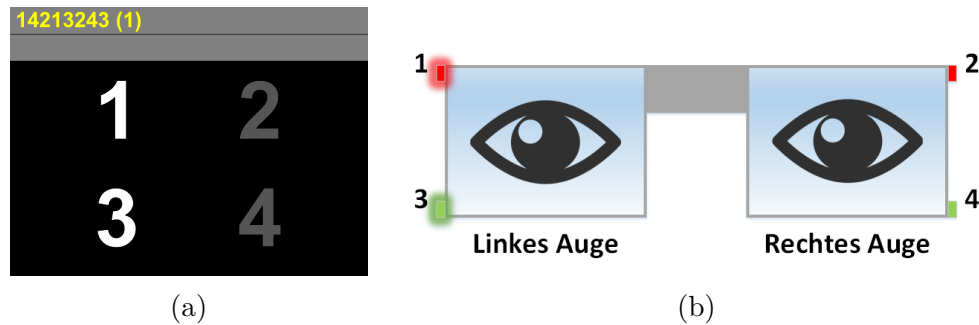


Abbildung 4.8.: a) P300-Matrix der Größe  $2 \times 2$ . Die Zeichen innerhalb der P300-Matrix leuchten zeilen- und spaltenweise und in zufälliger Reihenfolge auf. b) Zuordnung der Zeichen aus der P300-Matrix zu den vier LEDs des sBCI-Helmes. Wird eine Zeile oder Spalte innerhalb der P300-Matrix intensiviert, leuchten die entsprechenden LEDs des Helmes auf. Zu sehen ist die Intensivierung der ersten Spalte (LED 1 und 3).

Alternativ besteht die Möglichkeit, jede LED einzeln aufleuchten zu lassen. In diesem Fall würde jede LED nur noch halb so oft aufleuchten und die Wahrscheinlichkeit für ein Aufleuchten der selben LED direkt hintereinander wäre geringer. Jedoch werden nur halb so viele P300-Potenziale erzeugt, die für eine Klassifikation zur Verfügung stehen. Beim Zeilen/Spalten-Paradigma treten die Potenziale für eine Zeile und eine Spalte auf, wohingegen beim Einzelzeichen-Paradigma die Potenziale nur für eine LED auftreten. Die Gesamtanzahl an Stimuli beträgt jedoch bei beiden Paradigmen vier, wodurch die Zeit für die Stimulation bei beiden Paradigmen identisch ist. In einem Versuch wurden beide Paradigmen an einem Probanden getestet. Die Ergebnisse haben gezeigt, dass die Genauigkeiten und die ITR beider Paradigmen vergleichbar sind. Eine Beschreibung des Versuchs und die Ergebnisse befinden sich in Abschnitt 4.6.

Das Einzelzeichen-Paradigma stellt das einfachste der beiden Paradigmen dar, da hierbei eine direkte Zuordnung eines Stimulus zu einem Kommando möglich ist. Deshalb wird im Folgenden eine zeilen- und spaltenweise Intensivierung der LEDs betrachtet. Die Signalverarbeitung und die Kalibrierung sind leicht auf das Einzelzeichen-Paradigma übertragbar.



### 4.3.2. Signalverarbeitung

Dieser Abschnitt beschreibt die Signalverarbeitung zur Detektion von P300-Potenzialen. Die Signalverarbeitung nutzt einen zeitlichen Filter zur Mittelung der Signale über mehrere Wiederholungen. Daten aus einer Kalibrierungssitzung dienen zur Auswahl relevanter Merkmale und zum Training des Klassifikators. Die Amplituden ausgewählter Kanäle und Zeitpunkte bilden die Merkmale für einen linearen Klassifikator. Der Klassifikator bestimmt, welcher Stimulus ein P300-Potenzial evoziert hat.

#### 4.3.2.1. Signalvorverarbeitung

Zur Auswahl der für die Klassifikation von P300-Potenzialen relevanten Merkmale und zum Training des Klassifikators wird ein zuvor aufgenommener Trainingsdatensatz benötigt. Bei diesen Trainingsdaten muss bekannt sein, bei welchen Intensivierungen die Testperson ihre Konzentration auf den entsprechenden Stimulus gerichtet hat. Zuerst wird aus den Trainingsdaten nach jeder Intensivierung bzw. jedem Stimulus ein 800 ms langes Datensegment extrahiert. Die Extraktion der Daten wird für jeden Kanal durchgeführt. Anschließend wird jedes Datensegment mit einem Moving Average (MA)-Filter gefiltert, um Komponenten mit Frequenzen über 10 Hz aus den Signalen zu entfernen. Dies ermöglicht die Entfernung redundanter Informationen, da, im Vergleich zu den Frequenzen von P300-Potenzialen, die Abtastrate bei der Aufnahme der Daten deutlich höher ist. Danach wird, durch kanalweise Konkatenation der Datensegmente, für jede Intensivierung der Merkmalsvektor  $\mathbf{x}$  gebildet. Ein Merkmal ist die Amplitude eines Kanals zu einem bestimmten Zeitpunkt. Alle Merkmalsvektoren bilden zusammen die Merkmalsmatrix  $\mathbf{X}$ . Die Klassenzugehörigkeit der Merkmalsvektoren ist in dem Vektor  $\mathbf{y}$  festgehalten. Falls die Testperson ihre Konzentration auf einen Stimulus gerichtet hat, sind die Klassenbezeichnungen  $+1$ , andernfalls  $-1$ . Sowohl die Matrix  $\mathbf{X}$  als auch der Vektor  $\mathbf{y}$  dienen der Auswahl von Merkmalen und dem Training des Klassifikators.

Bevor die zu klassifizierenden Merkmalsvektoren der Testdaten reduziert und an den Klassifikator übergeben werden, findet für jeden Stimulus eine Mittelung der Vektoren über alle vorhandenen Wiederholungen statt.

#### 4.3.2.2. Merkmalsauswahl und Klassifikation

Die Bestimmung der Anwesenheit oder Abwesenheit eines evozierten P300-Potenzials ist ein binäres Klassifizierungsproblem. Zur Klassifikation wird eine Hyperebene verwendet, die die Merkmale der beiden Klassen voneinander trennt. Die Klassenzugehörigkeit eines Merkmalsvektors ist davon abhängig, auf welcher Seite der Hyperebene sich der Vektor befindet. Diese Hyperebene ist definiert durch [41]:

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (4.13)$$

wobei  $\mathbf{x}$  der Merkmalsvektor,  $\mathbf{w}$  der Vektor mit Gewichten für die Merkmale und  $b$  der Bias ist.

Es wird angenommen, dass ein P300-Potenzial während der Intensivierung einer der beiden Zeilen und Spalten auftritt. Klassifiziert werden die Zeile und Spalte, mit dem am höchsten bewerteten Merkmalsvektor der beiden Zeilen bzw. Spalten:

$$\text{Klassifizierte Zeile} = \arg \max_{\text{Zeile}} \left( \mathbf{w}^T \mathbf{x}_{\text{Zeile}} \right), \quad (4.14)$$

$$\text{Klassifizierte Spalte} = \arg \max_{\text{Spalte}} \left( \mathbf{w}^T \mathbf{x}_{\text{Spalte}} \right). \quad (4.15)$$

Nach dieser Regel wird die P300-Antwort mit der größten positiven Distanz von der Hyperebene ausgewählt, sofern die Klassenbezeichnungen  $+1$  für die Ziel- und  $-1$  für die Nicht-Zielstimuli sind. Dies ist idealerweise analog zur Auswahl der Antwort, die am stärksten die anhand von Trainingsdaten definierten Charakteristiken eines P300-Potenzials besitzt. Das vorhergesagte Zeichen befindet sich am Schnittpunkt der vor-

hergesagten Zeile und Spalte in der Matrix. Da die beiden Klassifikationsgleichungen invariant gegenüber dem konstanten Bias  $b$  sind, wird dieser nicht berechnet [93].

Zur Auswahl der für die Klassifikation von P300-Potenzialen relevanten Merkmale und zur Berechnung des Gewichtungsvektors  $\mathbf{w}$  kommt die schrittweise lineare Diskriminanzanalyse (engl. Stepwise Linear Discriminant Analysis (swLDA)) [40] zum Einsatz. Diese benötigt die aus den Trainingsdaten extrahierte Merkmalsmatrix  $\mathbf{X}$  und den dazugehörigen Vektor  $\mathbf{y}$  mit den Klassenbezeichnungen. Der Vorteil dieser Technik besteht in einer automatischen Reduktion des Merkmalsraumes. Bei einem Vergleich verschiedener Klassifikationsmethoden für ereigniskorrelierte Potenziale lieferte das swLDA-Verfahren die beste Leistung [93]. Das swLDA-Verfahren wurde, wie in der Arbeit [93], als eine schrittweise Analyse mit einem Vorwärts/Rückwärts-Ablauf implementiert. Es beginnt mit der Auswahl des am statistisch signifikantesten Merkmals zur Vorhersage der Zielklasse (mit einem  $p$ -Wert  $< p_{\text{enter}}$ ). Mit diesem Merkmal wird eine lineare Regressionsgleichung gebildet. Die Berechnung der Gewichte für die Merkmale erfolgt, mit einer Regression nach der Methode der kleinsten Quadrate, wie folgt [41]:

$$\mathbf{w} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}. \quad (4.16)$$

Nach jedem neu hinzugefügten Merkmal erfolgt eine schrittweise Analyse in Rückwärtsrichtung, um die am wenigsten signifikanten Merkmale (mit  $p$ -Werten  $> p_{\text{remove}}$ ) zu entfernen. Dieser Vorgang wird solange wiederholt, bis eine maximale Anzahl an Merkmalen erreicht ist oder keine weiteren Merkmale die Kriterien zum Einfügen oder Entfernen erfüllen. Entsprechend der Empfehlung aus der Literatur ist  $p_{\text{enter}} = 0,1$ ,  $p_{\text{remove}} = 0,15$  und die maximale Anzahl an Merkmalen beträgt 60 [93].

Die Reduktion der zu klassifizierenden Merkmalsvektoren der Testdaten erfolgt entsprechend der reduzierten Trainingsdaten.

### **4.3.3. Kalibrierung**

Obwohl die grundlegenden Merkmale eines evozierten P300-Potenzials für jeden Menschen identisch sind, gibt es einige individuelle Unterschiede. Zu diesen Unterschieden zählen die Amplitude und die Latenz der P300-Antwort [145]. Zum Training des Klassifikators aus dem vorherigen Abschnitt sind daher nutzerspezifische Daten erforderlich. Bei diesen Trainingsdaten muss bekannt sein, bei welchen Intensivierungen die Testperson ihre Konzentration auf den entsprechenden Stimulus gerichtet hat. Anhand der Kalibrierungsdaten von 10 Probanden wird ermittelt, wie viele Intensivierungen pro Stimulus notwendig sind, um eine hohe Klassifikationsgenauigkeit zu erzielen.

Zur Aufnahme der Trainingsdaten wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Der Ablauf der Kalibrierung wird über den P300-Speller von BCI2000 gesteuert, welcher um einen LED-Stimulus erweitert wurde. Die Anwendung fordert den Nutzer auf, seine Konzentration auf eine der vier LEDs zu richten, während die LEDs zeilen- und spaltenweise aufleuchten. Der Operator ermöglicht die Einstellung der Reihenfolge der zu betrachtenden LEDs, der Dauer des Aufleuchtens der LEDs (Stimulus-Intervall), der Ruhephase zwischen zwei Stimulationen (ISI) und der Anzahl an Intensivierungen pro Stimulus.

Neben der automatischen Auswahl von Merkmalen, mittels der schrittweisen linearen Diskriminanzanalyse, ist auch eine manuelle Bestimmung der Merkmale möglich. Die offline Analyse von BCI2000 ermöglicht die Charakterisierung einer Person anhand von Trainingsdaten. Das Programm zeigt die Kanäle und Zeitpunkte der Signale an, die eine Unterscheidung zwischen den Ziel- und Nicht-Zielstimuli ermöglichen.

#### 4.3.3.1. Versuchsteilnehmer

Insgesamt wurden Kalibrierungsdaten von 10 Probanden aufgenommen. Die Gruppe bestand aus 2 Frauen und 8 Männern. Das Alter der Probanden lag zwischen 18 und 33 Jahren, mit einem Durchschnittsalter von  $25,10 \pm 4,51$  Jahren. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### 4.3.3.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale und die im Helm integrierten LEDs zur visuellen Stimulation. Zur Aufnahme der EEG-Signale wurden alle Elektroden des sBCI-Helmes verwendet. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

#### 4.3.3.3. Versuchsprotokoll

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte eine Stunde inklusive Erläuterung der Aufgabenstellung, Präparieren des sBCI-Helmes und dem Waschen der Haare. In jedem der 6 Kalibrierungsdurchläufe mussten die Pro-

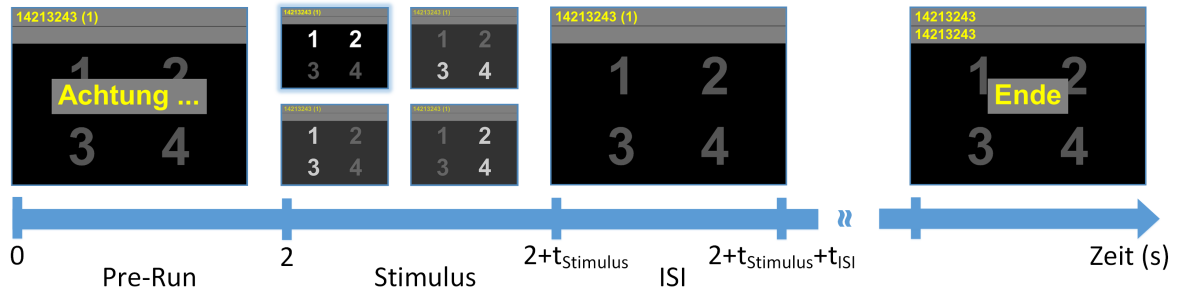


Abbildung 4.9.: Zeitlicher Ablauf der P300-Kalibrierung. Der Nutzer wird aufgefordert, seine Konzentration auf die angegebene LED zu richten und dessen Aufleuchten in Gedanken zu zählen. Während der Stimulus-Phase wird eine Zeile oder Spalte zufallsbestimmt intensiviert. Anschließend folgt das ISI, bei dem keine Intensivierung stattfindet. Der Wechsel beider Phasen wird so oft wiederholt, bis jede Zeile und Spalte mehrfach intensiviert wurde. Nach einer Sequenz wird entweder eine andere LED betrachtet oder die Kalibrierung endet.

banden jede der 4 LEDs einmal betrachten. Die Reihenfolge der zu betrachtenden LEDs war immer unterschiedlich. Das Stimulus-Intervall betrug 31,25 ms und das ISI 125 ms. Jeder Stimulus wurde innerhalb einer Sequenz 15 Mal intensiviert.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist in der Abbildung 4.9 zu sehen. Während der Kalibrierung sitzt der Proband vor einem Monitor, auf dem eine P300-Matrix zu sehen ist. Zusätzlich wird eine Testsequenz angezeigt, die angibt, auf welche der vier LEDs der Proband seine Konzentration richten soll. Innerhalb einer Sequenz leuchten die LEDs, synchron mit der P300-Matrix, mehrfach zeilen- und spaltenweise auf. Der Proband erhält die Aufgabe, das Aufleuchten der Ziel-LED in Gedanken zu zählen, bis eine andere LED zum Betrachten angegeben wird. Auf diese Weise ist es möglich, Intensivierungen zu kennzeichnen, je nachdem, ob sie für die zu betrachtende LED oder für eine andere LED in der Matrix auftreten.

#### 4.3.3.4. Evaluierung

Zur Evaluierung wurden, für jeden Probanden einzeln, die aufgenommenen Daten in einen Trainings- und einen Testdatensatz gleicher Größe aufgeteilt. Die Trainingsdaten




Abbildung 4.10.: Veränderung der Klassifikationsgenauigkeit mit steigender Anzahl an Intensivierungen pro Stimulus bei der Verwendung eines P300-BCIs mit vier Kontrollkommandos. Den Verteilungen liegen die Genauigkeiten aller Probanden zugrunde.

dienten zur Auswahl relevanter Merkmale und zum Training des Klassifikators. Entsprechend der Trainingsdaten wurden anschließend die Merkmale des Testdatensatzes extrahiert und klassifiziert. Um bestimmen zu können, wie viele Intensivierungen pro Stimulus notwendig sind, erfolgte die Mittelung der Testdaten über eine unterschiedliche Anzahl an Intensivierungen. Die Anzahl an Intensivierungen reichte von 1 bis 15. Zur Verarbeitung der Daten wurde die in Abschnitt 4.3.2 beschriebene Signalverarbeitung verwendet. Anhand der klassifizierten Testdaten wurde für jede Anzahl an Intensivierungen die Genauigkeit bestimmt.

Die Abbildung 4.10 zeigt die Veränderung der erzielten Klassifikationsgenauigkeit mit steigender Anzahl an Intensivierungen pro Stimulus. Jeder Verteilung liegen die Genauigkeiten aller Probanden zugrunde. Wie in der Abbildung zu sehen, steigen die Genauigkeiten mit einer zunehmenden Anzahl an Intensivierungen pro Stimulus an. Erst nach 5 Intensivierungen liegt der Median bei einer Genauigkeit von 100 %. Die Hälfte der Probanden erreicht dann jedoch lediglich eine Genauigkeit zwischen 75 und 100 %. Nach 6 Intensivierungen liegen fast alle Genauigkeiten über 90 % und nach 9 Intensivierungen liegen die Werte aller Probanden bei 100 %.

Eine Klassifikation nach einer Intensivierung pro Stimulus wäre wünschenswert, da dies eine hohe Kommunikationsgeschwindigkeit zur Folge hätte. Die Ergebnisse haben

jedoch gezeigt, dass die Genauigkeiten nach einer Intensivierung sehr gering sind. Der Median liegt lediglich bei 75 %. Eine geringe Genauigkeit führt jedoch zu einer geringen ITR und somit zu einer geringen Kommunikationsgeschwindigkeit. In einer Studie wurde deshalb das P300-BCI mit einer Klassifikation nach 5 Intensivierungen pro Stimulus eingesetzt. Dieser Wert liefert für viele der Probanden eine hohe Genauigkeit und stellt einen Kompromiss zwischen einer hohen Genauigkeit und einer hohen ITR dar. Eine Beschreibung des Versuchs und die Ergebnisse befinden sich in Abschnitt 4.6.

## **4.4. Zustandsautomaten für eine Roboterarmsteuerung**

Die Anzahl der zu steuernden Freiheitsgrade eines Roboterarmes, in kartesischen Koordinaten, ist größer als die Anzahl der zur Verfügung stehenden Kommandos. Daher ist immer nur die Steuerung eines Freiheitsgrades zur Zeit möglich. Die beiden Zustandsautomaten in diesem Abschnitt besitzen daher sieben Steuerungsgruppen: drei Gruppen für eine Translation entlang der x-, y- oder z-Achse (Translation X, Translation Y, Translation Z), drei weitere Gruppen für eine Rotation um die x-, y-, oder z-Achse (Rotation X, Rotation Y, Rotation Z) und eine letzte Gruppe für ein Öffnen und Schließen des Greifers (Greifer). Zusätzlich gibt es noch einen Modus, der einen Wechsel des Referenzsystems zwischen Basis- und Greiferkoordinaten ermöglicht (Referenzsystem). Im Initialzustand erfolgen alle translatorischen Bewegungen in Bezug zum Basiskoordinatensystem des Roboterarmes. Hingegen finden rotatorische Bewegungen immer in Bezug zum Greiferkoordinatensystem statt. Neben den Zuständen zur Steuerung des Roboterarmes existieren weitere Zustände, die lediglich der Verbindung zwischen den verschiedenen Steuerungsgruppen dienen. Der Eintritt in einen Zustand wird dem Nutzer akustisch mitgeteilt.

Vier Kommandos (1, 2, 3, 4) ermöglichen ein Umschalten zwischen den Steuerungsgruppen sowie eine Steuerung innerhalb der ausgewählten Gruppe. Diese Kommandos werden durch die Konzentration auf die vier LEDs des sBCI-Helmes ausgelöst. Die Zu-






Abbildung 4.11.: Zuordnung der LEDs zu den Umschalt- und Steuerkommandos. Die LEDs dienen zum Umschalten zwischen den Steuerungsgruppen und zur Steuerung innerhalb einer Gruppe. In einer Steuerungsgruppe kann der Nutzer eine diskrete Bewegung in positiver und negativer Richtung, eine Änderung der Schrittweite und ein Verlassen der Gruppe veranlassen.

ordnung der LEDs zu den Umschalt- und Steuerkommandos lässt sich der Abbildung 4.11 entnehmen. Da das Blinken der LEDs mit der Zeit ermüdend und belastigend auf den Nutzer wirkt, kann die visuelle Stimulation über eine Bewegungsvorstellung (MI) und über die LED selbst deaktiviert werden. Eine Aktivierung der LEDs kann nur über eine Bewegungsvorstellung erfolgen, da diese Modalität ohne eine externe Stimulation auskommt. Nach jedem verarbeiteten Kommando folgt eine Ruhephase von 2 s, damit der Anwender Gelegenheit erhält, seine Konzentration von der LED abzuwenden oder die Bewegungsvorstellung zu beenden. In einer Steuerungsgruppe bewirken die Kommandos 1 und 2 eine diskrete Bewegung in positiver bzw. negativer Richtung, das Kommando 3 eine Änderung der Schrittweite und das Kommando 4 ein Verlassen der Gruppe. Bei einem Eintritt in eine Steuerungsgruppe beträgt die Schrittweite 1 cm bei translatorischen Bewegungen und  $5^\circ$  bei rotatorischen Bewegungen. Die Änderung der Schrittweite findet in einem Ringdurchlauf statt. Zur Verfügung stehen die Schrittweiten 1, 2 und 4 cm bzw. 5, 10 und  $20^\circ$ . Eine Rückmeldung über die geänderte Schrittweite erhalten die Nutzer auf akustischem Wege. Nach einem Senden der Kommandos 1 und 2 erhalten die Nutzer eine visuelle und akustische Rückmeldung über die Bewegung des Roboters und keine zusätzliche Rückmeldung vom Zustandsautomaten.

Mit den beiden Zustandsautomaten stehen alle 14 Kommandos zur Robotersteuerung zur Verfügung, die für eine Translation, eine Rotation sowie ein Öffnen und Schließen des Greifers benötigt werden. Die Zustandsautomaten unterscheiden sich lediglich in der Art des Umschaltens zwischen den Steuerungsgruppen. Bei der Steuerung innerhalb einer Gruppe gibt es keine Unterschiede. Im Folgenden wird auf die beiden Zustandsautomaten näher eingegangen.

#### **4.4.1. 1-Tupel Zustandsautomat**

Wie in dem Diagramm der Abbildung 4.12 zu sehen, nutzt der 1-Tupel Zustandsautomat immer ein Kommando für eine Transition zwischen den Zuständen. Aufgrund der begrenzten Anzahl an Kommandos sind die folgenden fünf Verbindungszustände notwendig: Stand-by, Aktiv, Arm, Translation und Rotation. In diesen Zuständen findet keine Steuerung des Roboters statt. Im Zustand Stand-by sind die LEDs deaktiviert. Über eine Bewegungsvorstellung erfolgt ein Wechsel in den Aktivzustand. In diesem Zustand sind die LEDs aktiviert. Die Kommandos 1 bis 3 bewirken eine Transition in einen der unteren Zustände und das Kommando 4 dient immer für einen Rücksprung in den vorherigen Zustand. Der Wechsel des Referenzsystems ist mit einem automatischen Rücksprung verbunden. Neben einer Bewegungsvorstellung lassen sich auch die LEDs über das Kommando 4 deaktivieren.

Der Nachteil dieses Konzepts besteht darin, dass die Kommandosequenzen, die für einen Wechsel zwischen den Steuerungsgruppen notwendig sind, in ihrer Länge variieren. Für einen Wechsel von Translation X zu Translation Y ist beispielsweise eine geringere Anzahl an Kommandos notwendig als für einen Wechsel von Translation X zu Rotation Y (2 im Vergleich zu 4 Kommandos). Da dem Nutzer keine visuelle Darstellung des Zustandsautomaten präsentiert wird, muss dieser in der Lage sein, sich den Zustandsautomaten gedanklich vorzustellen, um die Kommandosequenzen planen zu können. Dies ist mit einer hohen mentalen Belastung des Nutzers verbunden.

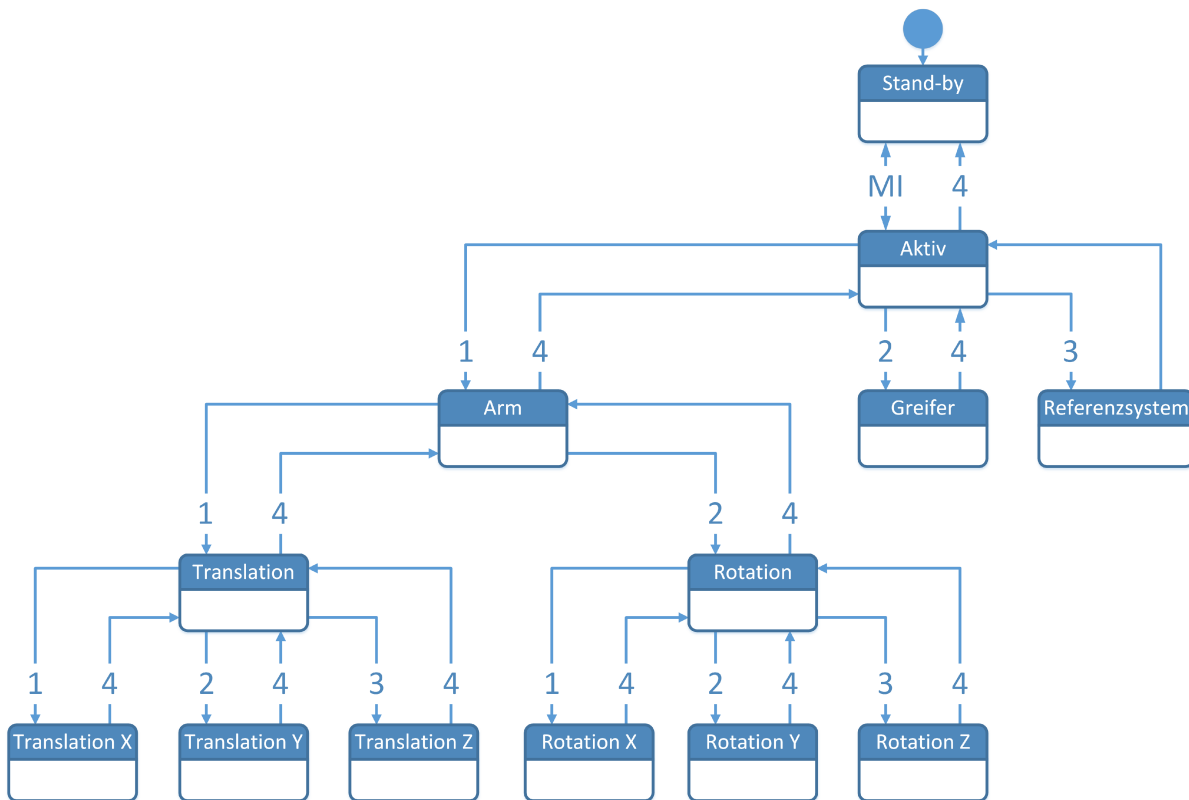


Abbildung 4.12.: 1-Tupel Zustandsautomat für die schrittweise Steuerung eines Roboterarmes. Die Aktivierung des Systems erfolgt mit einer Bewegungsvorstellung (MI) und das weitere Umschalten und Steuern über die vier aktivierten LEDs des sBCI-Helms (1, 2, 3, 4). In einer Steuerungsgruppe bewirken die Kommandos 1 und 2 eine Bewegung in positiver bzw. negativer Richtung, das Kommando 3 eine Änderung der Schrittweite und das Kommando 4 ein Verlassen der Gruppe. Das Referenzsystem lässt sich zwischen Basis- und Greiferkoordinaten wechseln.

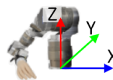

#### 4.4.2. 2-Tupel Zustandsautomat

Beim 2-Tupel Zustandsautomaten ist für eine Transition eine Sequenz von zwei LED-Kommandos erforderlich. Dieses Konzept benötigt nur die beiden Verbindungszustände Stand-by und Aktiv, in denen keine Steuerung des Roboters stattfindet. Im Zustand Stand-by sind die LEDs deaktiviert. Über eine Bewegungsvorstellung erfolgt ein Wechsel in den Aktivzustand. In diesem Zustand sind die LEDs aktiviert. Vom Aktivzustand aus muss der Nutzer immer zwei LED-Kommandos hintereinander senden, um in eine Steuerungsgruppe gelangen zu können. Eine Zuordnung der 2-Tupel Kommandos zu den Steuerungsgruppen lässt sich der Tabelle 4.1 entnehmen.

Zunächst erscheint es schwierig, sich jede der insgesamt 16 Kommandosequenzen zu merken. Daher wurde bei der Zuordnung der Sequenzen zu den Aktionen eine einheitliche Konvention verwendet. Um eine Bewegung in Relation zur x-, y- oder z-Achse ausführen zu können, muss das erste Kommando stets eine 1, 2 bzw. 3 sein. Alle anderen Aktionen beginnen immer mit dem Kommando 4. Ob die Aktion eine translatorische oder rotatorische Bewegung darstellt und in welche Achsenrichtung die Bewegung erfolgen soll, entscheidet sich mit dem zweiten Kommando. Eine Translation in positiver oder negativer Richtung erfolgt immer dann, wenn das zweite Kommando eine 1 bzw. 2 ist. Dies gilt neben den drei Achsen ebenfalls für die Finger des Greifers. Für eine rotatorische Bewegung in positiver oder negativer Richtung muss das zweite Kommando eine 3 bzw. 4 sein. Da die Finger des Greifers keine rotatorische Bewegung ausführen können, lassen sich zwei Sequenzen für zusätzliche Aktionen verwenden. Über diese ist es möglich, dass Referenzsystem zu wechseln oder in den Zustand Stand-by zu wechseln und hierüber die LEDs zu deaktivieren.

Wird innerhalb eines Zeitfensters von 10 s kein zweites Kommando gesendet, wird das erste Kommando gelöscht. Im Falle eines fehlerhaften ersten Kommandos kann der Nutzer hierdurch den Fehler korrigieren. Eine Rückmeldung über die detektierten Kommandos und das Zurücksetzen des ersten Kommandos erhalten die Nutzer auf akusti-

Tabelle 4.1.: Zuordnung der 2-Tupel Kommandos zu den Steuerungsgruppen. Die bebilderten Bewegungen des Roboterarmes beziehen sich auf das Basiskoordinatensystem. Hierbei wird angenommen, dass der Nutzer frontal auf den oben angezeigten Roboterarm blickt.

Aktion		Kommando		
		1.	2.	
X	Translation	+	1	→
		-	1	←
	Rotation	+	1	↺
		-	1	↻
Y	Translation	+	2	↑
		-	2	↓
	Rotation	+	2	↺
		-	2	↻
Z	Translation	+	3	↑
		-	3	↓
	Rotation	+	3	↺
		-	3	↻
Greifer	Translation	+	4	↔
		-	4	↔
Referenzsystem	Basis/Greifer	4	3	
Stand-by		4	4	

schem Wege. Innerhalb einer Steuerungsgruppe löst das Kommando 4 einen Rücksprung zum Aktivzustand aus. Der Wechsel des Referenzsystems ist mit einem automatischen Rücksprung verbunden.

Der Vorteil dieses Konzepts besteht darin, dass für jeden Wechsel der Steuerungsgruppe immer die gleiche Anzahl an Kommandos benötigt wird. Dieser Wert ist kleiner oder gleich der Anzahl an Kommandos, die beim 1-Tupel Zustandsautomaten benötigt werden. Ein Umschalten zwischen den Steuerungsgruppen ist daher einfacher und schneller durchzuführen. Außerdem wird bei einer Transition in eine Steuerungsgruppe sofort eine Bewegung ausgeführt.

## **4.5. Implementierung der Roboterarmregelung**

Wie in den vorherigen Abschnitten beschrieben, wird zuerst durch die Verarbeitung der aufgenommenen EEG-Signale die Intention des Nutzers nachvollzogen. Die klassifizierten diskreten BCI-Kommandos dienen anschließend als Eingangssignale für den Zustandsautomaten. Mit dem Zustandsautomaten und den BCI-Kommandos kann der Anwender zwischen den Steuerungsgruppen des Roboterarmes umschalten und diskrete Steuerkommandos an die Regelung des Roboters senden. In dieser Arbeit wird für die Experimente der Roboterarm Lightweight Arm (LWA) 3 des Unternehmens Schunk verwendet. Dieser besitzt sieben Freiheitsgrade in Gelenkkoordinaten. Er ist mit dem Greifer PG70 und einem Kraft-Momenten-Sensor ausgerüstet. Bei dem Greifer handelt es sich um einen 2-Finger-Parallelgreifer mit einem Hub von 68 mm. Die Implementierung der Roboterarmregelung erfolgte mit dem Software-Framework ROS und dem Softwarepaket MoveIt!.

ROS [150] stellt eine strukturierte Kommunikationsschicht über den Betriebssystemen eines Rechnerverbundes bereit. Die grundlegenden Konzepte der ROS-Implementierung sind *Nodes*, *Messages*, *Topics* und *Services*. Nodes sind Prozesse, die Berechnungen durchführen. Sie kommunizieren über einen Nachrichtenaustausch miteinander. Eine

## 4.5. Implementierung der Roboterarmregelung

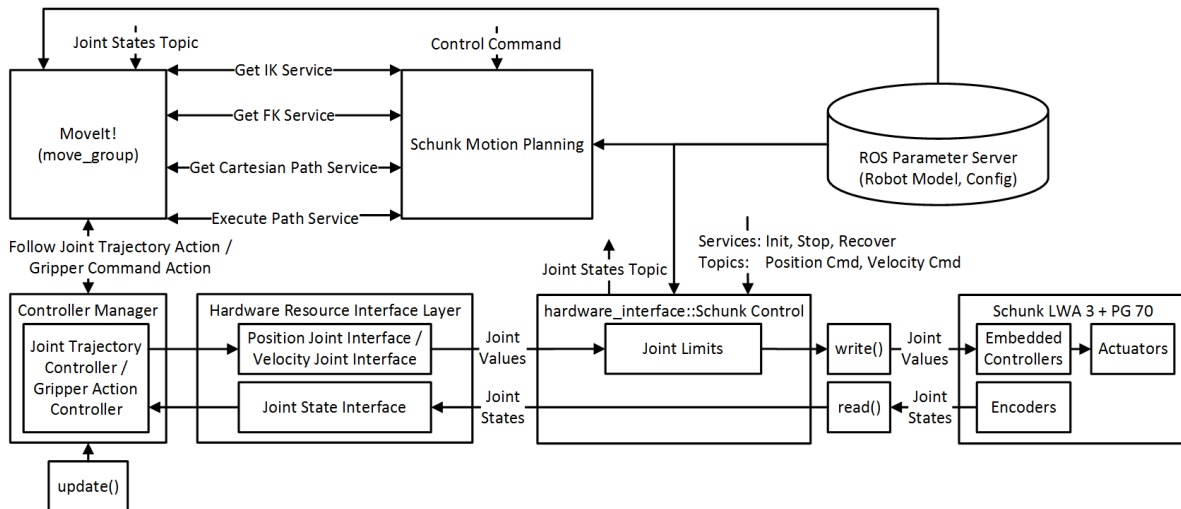


Abbildung 4.13.: Darstellung der in ROS implementierten Roboterarmregelung.

Nachrichte ist eine streng typisierte Datenstruktur. Der Nachrichtenaustausch kann über einen Topic oder über einen Service erfolgen. Über einen Topic können mehrere Nodes unabhängig voneinander Nachrichten austauschen, indem sie Nachrichten auf dem Topic veröffentlichen und lesen. Bei einem Service wird eine Nachricht für die Anfrage und eine für die Antwort benötigt. Anders als bei den Topics, kann immer nur ein Node zur Zeit einen Service in Anspruch nehmen. Nodes können in einem laufenden ROS-basierten System gestartet und beendet werden. Nachrichtenströme lassen sich speichern und später wiedergeben. Die Bedienung eines ROS-basierten Systems erfolgt über die Konsole.

MoveIt! [35] ist eine in ROS integrierte Ansammlung von Softwarepaketen. Diese ermöglichen einem Roboter, mit Hilfe von Sensoren, eine Darstellung ihrer Umgebung zu erstellen, kollisionsfreie Bewegungsabläufe zu planen und die Bewegungen während der laufenden Umgebungsbeobachtung auszuführen. Über ein Konfigurationsprogramm erfolgt die individuelle Anpassung der Software an den Roboter. Das Programm benötigt die beiden Unified Robot Description Format (URDF)- und Semantic Robot Description Format (SRDF)-Dateien, die alle notwendigen Parameter des Roboters beinhalten.

Ein Diagramm der Roboterarmregelung ist in der Abbildung 4.13 zu sehen. Bevor es zu einer Verarbeitung der Roboterkommandos kommt, muss eine Initialisierung des Ro-

boterarmes und des Greifers stattfinden. Die Initialisierung erfolgt über einen Service, der an den Node Schunk Control gesendet wird. Dieser ist für die direkte Kommunikation mit der Hardware verantwortlich. Für den Arm und den Greifer existiert jeweils ein Node. Zur Verhinderung von Konflikten besitzen beide Nodes einen eigenen Namespace. Über Topics kann der Nutzer die Positionen und Geschwindigkeiten der Gelenkwinkel verändern. Sämtliche Parameter für die Konfiguration befinden sich auf dem ROS Parameter Server, von dem alle Nodes die notwendigen Parameter einlesen. Empfängt der Node Schunk Motion Planning ein Roboterkommando über das UDP-Netzwerkprotokoll, werden folgende Schritte bearbeitet:

1. Schunk Control liest die von den Drehgebern gelieferten Gelenkwerte ein und veröffentlicht diese Werte auf dem Topic Joint States.
2. Schunk Motion Planning berechnet, über die Vorwärtskinematik von MoveIt!, die aktuelle Pose des Greifers. MoveIt! nutzt dabei die aktuellen Gelenkwerte vom Topic Joint States und das Modell des Roboters vom Parameter Server.
3. Ausgehend von der aktuellen Pose und dem empfangenen Roboterkommando, berechnet Schunk Motion Planning die neue Pose des Greifers.
4. Mit der inversen Kinematik von MoveIt! erhält Schunk Motion Planning die neuen Gelenkwerte. Diese Werte werden in einem Plan gespeichert und zur Ausführung an MoveIt! gesendet. Bei großen Schrittweiten wird der Pfadplaner von MoveIt! verwendet, der mit Hilfe der inversen Kinematik eine komplette Trajektorie berechnet. Pläne, die zu großen Änderungen der Gelenkwinkel führen, werden verworfen.
5. MoveIt! sendet die zu fahrende Trajektorie für den Arm und die Kommandos für den Greifer an die entsprechenden Regler. Ein Manager sorgt für die Verwaltung von allen Reglern.
6. Über eine Schnittstelle erhalten die Regler in Echtzeit die aktuellen Gelenkwerte von Schunk Control. Nach einer Aktualisierung der Regler senden diese die neuen



Gelenkwerte, über eine weitere Schnittstelle, an Schunk Control. Schunk Control sendet die neuen Gelenkwerte an die eingebetteten Regler des Armes und des Greifers, die die Aktuatoren ansprechen.

Die inverse Kinematik nutzt den TRAC-IK Algorithmus [16], um für eine Pose des Greifers die notwendigen Gelenkwinkel zu berechnen. Der Algorithmus nutzt zwei unterschiedliche Methoden, die zeitgleich nach einer Lösung suchen. Sobald eine Methode eine Lösung gefunden hat, wird diese zurückgegeben und der Algorithmus terminiert. Zur Reduzierung der Rechenzeit nutzt die erste Methode die inverse Jacobi-Matrix. Die Anzahl an notwendigen Iterationen wird dynamisch über die vorgegebene Berechnungszeit bestimmt. Für eine Erhöhung der Lösungsrate nutzt die zweite Methode Sequential Quadratic Programming (SQP). Dies ist ein iterativer Algorithmus für ein nicht-lineares Optimierungsproblem, der besser Vorgaben, wie die Begrenzung der Gelenkwinkel, handhaben kann. Aufgrund der Begrenzungen der Gelenkwinkel kann es passieren, dass beide Methoden nur ein lokales Minimum als Lösung finden. In diesem Fall suchen beide Methoden, durch die zufällige Auswahl eines neuen Startwertes, weiter nach einer optimalen Lösung.

## **4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten**

Im Rahmen dieser Studie wurden zuerst die Umschalt- und Steuermodalitäten verglichen. Eine Übersicht über das dabei verwendete System befindet sich im Abschnitt 4.1. Der Roboter empfing während des Experiments keine Kommandos und blieb ausgeschaltet. Die Probanden nutzten das frequenzbasierte SSVEP-BCI aus Abschnitt 4.2 und das P300-BCI aus Abschnitt 4.3 zur Bedienung des 1-Tupel Zustandsautomaten aus Abschnitt 4.4. Die Stimulation erfolgte über die LEDs des in Abschnitt 3.1 beschriebenen sBCI-Helmes. Für einen Vergleich der LED-Größe nutzten die Probanden ebenfalls die

großen LEDs aus Abschnitt 4.2.1 für das frequenzbasierte SSVEP-BCI. Zusätzlich führten die Probanden die Tests mit dem phasenbasierten SSVEP-BCI aus Abschnitt 4.2 durch, um einen Vergleich der beiden SSVEP-Paradigmen zu ermöglichen. Hierbei nutzten die Probanden ebenfalls die großen LEDs, da unter Verwendung der LEDs des sBCI-Helmes die Phaseninformation nicht zuverlässig ermittelt werden konnte. Das P300-BCI verwendete das Zeilen/Spalten-Paradigma. Lediglich ein Proband nutzte für einen Vergleich zusätzlich das Einzelzeichen-Paradigma.

In einem weiteren Experiment wurden die beiden Zustandsautomaten aus Abschnitt 4.4 verglichen. Die Probanden nutzten das zuvor getestete und am besten bewertete frequenzbasierte SSVEP-BCI als Umschalt- und Steuermodalität für den 1-Tupel und den 2-Tupel Zustandsautomaten. Die Stimulation erfolgte über die LEDs des sBCI-Helmes.

Anhand der ermittelten Genauigkeiten, Kommunikationsgeschwindigkeiten und Bearbeitungszeiten wurden die beste Modalität und der beste Zustandsautomat ausgewählt und in dem in Abschnitt 4.7 beschriebenen Test der schrittweisen Roboterarmsteuerung verwendet.

#### **4.6.1. Versuchsteilnehmer**

An jedem der vier Experimente, zum Vergleich der Umschalt- und Steuermodalitäten, nahmen 8 bis 10 Probanden teil. Aufgrund eines hohen zeitlichen Abstandes zwischen den Experimenten, waren die Konstellationen der Versuchsteilnehmer stets unterschiedlich. Die Probanden, die das frequenzbasierte SSVEP-BCI und die sBCI-LEDs nutzten, steuerten zusätzlich zum 1-Tupel ebenfalls den 2-Tupel Zustandsautomaten. Die Informationen über die Versuchsteilnehmer, hinsichtlich Geschlechts und Alters, sind der Tabelle 4.2 zu entnehmen. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter

#### 4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten

Tabelle 4.2.: Informationen über die Probanden, die an der Studie zum Vergleich der Umschalt- und Steuermodalitäten und der Zustandsautomaten teilnahmen.

Paradigma	Stimulator	Geschlecht		Alter			
		weibl.	männl.	Min.	Max.	Mittelw.	SD
SSVEP (Frequenz)	sBCI-LEDs	2	8	18	32	24,90	4,23
P300	sBCI-LEDs	2	8	18	33	25,10	4,51
SSVEP (Frequenz)	Große LEDs	4	4	23	34	25,63	3,93
SSVEP (Phase)	Große LEDs	4	4	23	34	25,75	3,85

der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Versuche fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### 4.6.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Das SSVEP-BCI nutzte 8 Elektroden ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex. Für das P300-BCI wurden alle Elektroden des sBCI-Helmes verwendet und die optimalen Kanäle über die Kalibrierung bestimmt. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Das phasenbasierte SSVEP-BCI benutzte die Blinksequenz der unteren linken LED mit der Phase 0° als Referenzsignal. Hierfür wurde der 5 V Ausgang des LED-Mustergenerators mit dem Digitaleingang des Verstärkers verbunden. Bis auf das Referenzsignal erfolgte eine Filterung der Signale mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz).

### **4.6.3. Versuchsprotokoll**

Vor dem Versuch mussten die Probanden eine Kalibrierung durchführen. Eine Beschreibung der verwendeten Kalibrierung für das SSVEP-BCI befindet sich in Abschnitt 4.2.3 und für das P300-BCI in Abschnitt 4.3.3.

Beim SSVEP-BCI wurden im Rahmen der Kalibrierung die optimale Stimulationsfrequenz für das phasenbasierte SSVEP und die vier optimalen Frequenzen für das frequenzbasierte SSVEP bestimmt. Der frequenzbasierte Ansatz nutzte Schwellwerte für die Klassifikation, die für jeden Nutzer empirisch ermittelt wurden. Eine SVM, mit einem RBF-Kernel, wurde beim phasenbasierten Ansatz zur Klassifikation eingesetzt. Dieser Klassifikator benötigte zum Training die zuvor aufgenommenen Kalibrierungsdaten. Die Berechnung der räumlichen Filter für die Berechnung der Stimulationsfrequenzen erfolgte mit der MCC-Methode. Zur Berechnung der Phase wurde der erste räumlich gefilterte Kanal verwendet. Der räumliche Filter zur Phasenberechnung wurde mittels der Trainingsdaten und der MCC-Methode berechnet. Neben den Stimulationsfrequenzen wurden noch weitere Frequenzen betrachtet, um die Stabilität des Systems zu verbessern. Diese lagen beim frequenzbasierten Ansatz mit einer Abweichung von 0,5 Hz um die Stimulationsfrequenzen. Beim phasenbasierten Ansatz wurden 8 weitere Frequenzen betrachtet, die in Schritten von 0,5 Hz um die Stimulationsfrequenz lagen. Betrachtet wurden immer die ersten beiden Harmonischen.

Insgesamt musste jeder Proband 6 Kalibrierungsdurchläufe für das P300-BCI absolvieren, um ausreichend Daten für das Training des Klassifikators zu erhalten. In jedem Durchlauf mussten die Probanden jede der 4 LEDs einmal betrachten. Die Reihenfolge der zu betrachtenden LEDs war immer unterschiedlich. Bei der Kalibrierung und der späteren Verwendung des P300-BCIs betrug das Stimulus-Intervall 31,25 ms und das ISI 125 ms. Während der Kalibrierung wurde jede Sequenz 15 Mal wiederholt. Bei der darauffolgenden Verwendung des Systems wurden die Wiederholungen auf 5 reduziert, um eine hohe Kommunikationsgeschwindigkeit zu erzielen. Auch wurde ein empirisch

#### 4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten

Tabelle 4.3.: Aufgaben für die Bedienung des Zustandsautomaten.

Aufgabe	Beschreibung
1	Translation entlang der x-Achse um 1 cm in positiver Richtung und Öffnen des Greifers um 1 cm.
2	Translation entlang der x-Achse um 1 cm in positiver Richtung und Änderung des Referenzsystems.
3	Translation entlang der x-Achse um 1 cm in positiver Richtung und Rotation um die x-Achse um 5° in positiver Richtung.
4	Translation entlang der x-Achse um 1 cm in positiver Richtung, Translation entlang der y-Achse um 1 cm in positiver Richtung und Translation entlang der z-Achse um 1 cm in positiver Richtung.

ermittelter Schwellwert verwendet, damit das P300-BCI nur in den Sequenzen ein Kommando erzeugt, in denen der Nutzer sich auf eine LED konzentriert hat. Ansonsten würde das System nach jeder Sequenz ein Kommando senden und es gäbe keinen Nichtkontrollzustand.

Nach der Kalibrierung mussten die Probanden die vier Aufgaben aus der Tabelle 4.3 absolvieren. Die Aufgaben wurden so gewählt, dass die Nutzer zuerst die Steuerungsgruppe für eine Translation entlang der x-Achse auswählten und anschließend einen Wechsel der Steuerungsgruppe ausführten. Insgesamt führten die Probanden alle grundlegenden Wechsel der Steuerungsgruppe aus. Sie wechselten zur Gruppe des Greifers, des Referenzsystems und der Rotation um die x-Achse und führten außerdem einen Wechsel aller drei Achsen aus. Vor der eigentlichen Versuchsdurchführung wurden dem Probanden die Steuerungskonzepte des 1-Tupel und des 2-Tupel Zustandsautomaten erläutert. Jeder Proband erhielt die Gelegenheit, sich vorher mit der Steuerung vertraut zu machen. Jede Aufgabe wurde, je nach Leistung des Probanden, zwischen 3 und 5 Mal wiederholt.

#### **4.6.4. Evaluierung der Umschalt- und Steuermodalitäten**

Für einen Vergleich der verwendeten Umschalt- und Steuermodalitäten wurden die Genauigkeiten und die ITR für jeden einzelnen Versuch ermittelt. Eine ausführliche Beschreibung der beiden Parameter lässt sich dem Abschnitt 2.5 entnehmen. Die Genauigkeit ergibt sich aus dem Verhältnis der korrekten Kommandos zu allen erkannten Kommandos. Unter korrekten Kommandos sind alle Kommandos zu verstehen, die eine schnellstmögliche Bearbeitung der zu erledigenden Aufgabe ermöglichen. Die Anzahl an Kommandos beträgt vier, aufgrund der vier LEDs des sBCI-Helmes. Zur Berechnung der ITR wurde die Zeit ab dem Einschalten der LEDs bis zur Beendigung der Aufgabe gemessen. Die ausführlichen Ergebnisse befinden sich im Anhang in den Tabellen B.1 bis B.4.

Alle Probanden waren nach einer kurzen Testphase in der Lage, die gestellten Aufgaben zu erledigen. In den Abbildungen 4.14 bis 4.17 ist die Leistung der einzelnen Probanden zu sehen. Die Diagramme zeigen für jeden Probanden die über alle Versuche gemittelte Genauigkeit und ITR sowie die gesamten Mittelwerte beider Parameter. Bei allen Paradigmen betrug die maximal mögliche ITR 60 bits/min, da nach jedem Kommando das System eine Ruhepause von 2 s vorgab.

Unter Verwendung der LEDs des sBCI-Helmes und des frequenzbasierten SSVEP-BCIs erreichten die Probanden im Mittel eine Genauigkeit von  $98,19 \pm 3,79$  % und eine ITR von  $38,04 \pm 11,11$  bits/min (Abbildung 4.14). Eine Genauigkeit von 100 % erreichten die Probanden 1 und 5. Die höchste ITR erzielte Proband 9 mit 51,47 bits/min. Proband 6 erreichte mit 95,91 % die geringste Genauigkeit und Proband 2 mit 19,88 bits/min die geringste ITR. Verglichen mit dem Test des sBCI-Systems aus Abschnitt 3.3 wurde eine Verbesserung der mittleren Genauigkeit von 87,27 auf 98,19 % und der mittleren ITR von 15,99 auf 38,04 bits/min erreicht. Vor allem die Betrachtung von zusätzlichen Frequenzen, im Bereich um die Stimulationsfrequenzen, führte zu stabileren und somit

#### 4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten




Abbildung 4.14.: Gemittelte ITR und Genauigkeit von jedem Probanden, der das frequenzbasierte SSVEP-BCI und die LEDs des sBCI-Helmes nutzte.

besseren Ergebnissen. Weiterhin ließen sich mit kalibrierten Frequenzen bessere Ergebnisse erzielen als mit einem festen Frequenzsatz. Auch die räumliche Filterung nach der MCC-Methode, anstelle der MEC-Methode, führte zu höheren Genauigkeiten.

Die Probanden, die die LEDs des sBCI-Helmes und das P300-BCI nutzten, erreichten im Mittel eine Genauigkeit von  $98,29 \pm 4,46$  % und eine ITR von  $22,39 \pm 4,99$  bits/min (Abbildung 4.15). Proband 3 erzielte mit 100 % die höchste Genauigkeit und Proband 1 mit 25,93 bits/min die höchste ITR. Das schlechteste Ergebnis erzielte Proband 4 mit einer Genauigkeit von 94,32 % und einer ITR von 14,48 bits/min. Der Proband 5 verwendete beide Arten der Stimulation. Mit dem Zeilen/Spalten-Paradigma erzielte er eine Genauigkeit von 98,33 % und eine ITR von 22,30 bits/min. Vergleichbare Ergebnisse erzielte er mit dem Einzelzeichen-Paradigma. Hiermit erzielte er eine Genauigkeit von 97,44 % und eine ITR von 19,84 bits/min.

Mit den großen LEDs und dem frequenzbasierten SSVEP-BCI erreichten die Probanden eine mittlere Genauigkeit von  $99,53 \pm 2,33$  % und eine ITR von  $46,88 \pm$




Abbildung 4.15.: Gemittelte ITR und Genauigkeit von jedem Probanden, der das P300-BCI und die LEDs des sBCI-Helmes nutzte.

7,94 bits/min (Abbildung 4.16). Das beste Ergebnis erzielte Proband 2 mit einer Genauigkeit von 100 % und einer ITR von 55,33 bits/min. Proband 1 lieferte mit einer Genauigkeit von 97,84 % und einer ITR von 32,74 bits/min die schlechteste Leistung ab.

Im Mittel erreichten die Probanden mit den großen LEDs und dem phasenbasierten SSVEP-BCI eine Genauigkeit von  $95,95 \pm 6,54$  % und eine ITR von  $38,54 \pm 14,13$  bits/min (Abbildung 4.17). Mit einer Genauigkeit von 100 % und einer ITR von 55,36 bits/min erzielte Proband 2 das beste Ergebnis. Die schlechteste Leistung lieferte Proband 1 mit einer Genauigkeit von 90,58 % und einer ITR von 18,88 bits/min ab.

In den Abbildungen 4.18a und 4.18b sind die Verteilungen aller ermittelten Genauigkeiten und ITR der verschiedenen Paradigmen zu sehen. Mit Ausnahme des phasenbasierten SSVEP-BCIs erreichten die Probanden überwiegend eine Genauigkeit von 100 %. Lediglich einige wenige Ausreißer sorgen für eine mittlere Genauigkeit von unter 100 %.



#### 4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten




Abbildung 4.16.: Gemittelte ITR und Genauigkeit von jedem Probanden, der das frequenzbasierte SSVEP-BCI und die großen LEDs nutzte.




Abbildung 4.17.: Gemittelte ITR und Genauigkeit von jedem Probanden, der das phasenbasierte SSVEP-BCI und die großen LEDs nutzte.

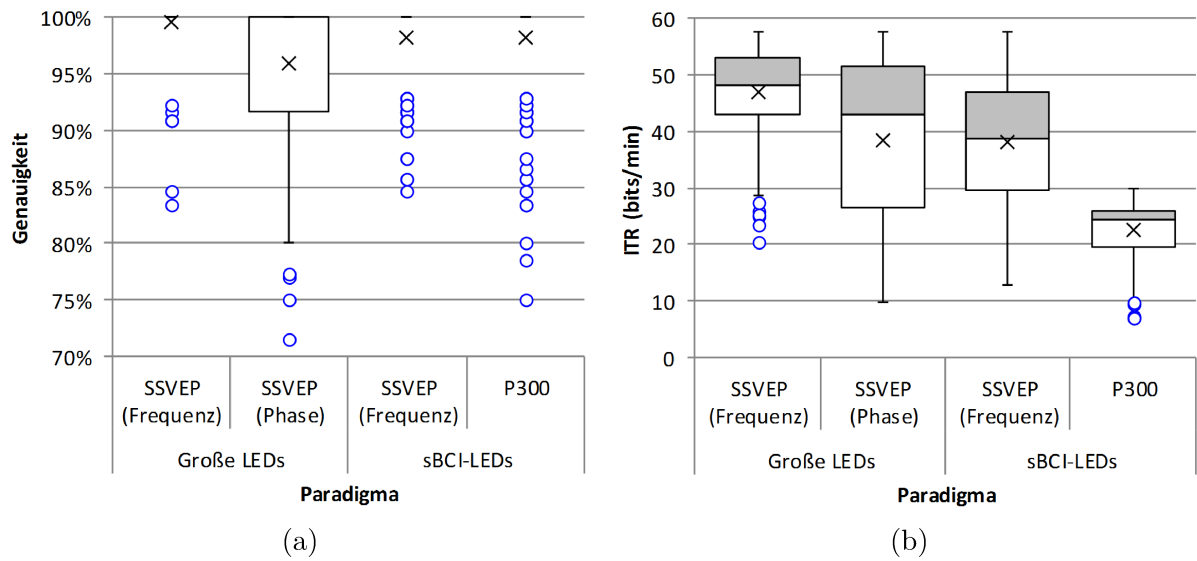


Abbildung 4.18.: Verteilungen der Genauigkeiten (a) und der ITR (b) unter Nutzung der verschiedenen Paradigmen. Den Verteilungen liegen alle ermittelten Werte des jeweiligen Paradigmas zugrunde.

Beim phasenbasierten SSVEP-BCI liegen lediglich 50 % der Werte bei einer Genauigkeit von 100 % und 75 % der Werte über einer Genauigkeit von 91,67 %.

Die maximale ITR ist bei allen SSVEP-basierten Paradigmen fast identisch und liegt bei ca. 57,6 bits/min. Ein Vergleich der beiden frequenzbasierten SSVEP-BCIs zeigt, dass die Vergrößerung der LEDs eine Erhöhung der ITR um ca. 10 bits/min bewirkt. Mit den LEDs des sBCI-Helms liegen 75 % der Werte über 29,67 bits/min und mit den großen LEDs über 43,10 bits/min. Ein Vergleich des frequenz- und phasenbasierten Ansatzes kann nur für die großen LEDs erfolgen. Bei beiden Ansätzen liegen 25 % der Werte über 51,68 bits/min. Aufgrund der höheren Genauigkeit, erreichten die Probanden insgesamt mit dem frequenzbasierten Ansatz höhere Kommunikationsgeschwindigkeiten. Bei dem phasenbasierten SSVEP-BCI liegen 75 % der Werte nur über 26,45 bits/min. Aufgrund seiner synchronen Operationsweise, ist die ITR beim P300-BCI überwiegend geringer als bei dem asynchron operierenden SSVEP-BCI. Seine maximale ITR liegt bei 29,75 bits/min und 75 % der Werte liegen über 19,39 bits/min.

Zusammenfassend lässt sich feststellen, dass das frequenzbasierte SSVEP-BCI die besten Ergebnisse liefert. Der Einsatz eines phasenbasierten SSVEP-BCIs empfiehlt sich nur dann, wenn für den Probanden keine ausreichende Anzahl an Stimulationsfrequenzen gefunden werden kann. Dieser Fall kann eintreten, wenn die Frequenzen über 30 Hz liegen sollen (siehe Abschnitt 4.2.3.4), um die Gefahr von Epilepsie zu verringern und die Nutzerfreundlichkeit zu erhöhen. Das P300-BCI müsste bereits nach einer einzigen Wiederholung der Sequenz die Daten klassifizieren, um eine mit dem SSVEP-BCI vergleichbare Geschwindigkeit erzielen zu können. Mit dem verwendeten Algorithmus würde dies jedoch zu sehr geringen Genauigkeiten führen, weshalb eine Mittelung über mehrere Wiederholungen erforderlich ist. Die großen LEDs führen zwar zu einer höheren ITR im Vergleich zu den LEDs des sBCI-Helmes, jedoch empfanden die Probanden die großen LEDs als ermüdend und störend. Daher wurden das frequenzbasierte SSVEP-BCI und die LEDs des sBCI-Helmes zur Roboterarmsteuerung ausgewählt.

##### 4.6.5. Evaluierung der Zustandsautomaten

Für einen Vergleich des 1- und 2-Tupel Zustandsautomaten wurden die Zeiten zur Bearbeitung der vier Aufgaben gemessen. Zusätzlich wurden die Genauigkeiten und die ITR, wie beim Vergleich der Umschalt- und Steuermodalitäten, ermittelt. Die ausführlichen Ergebnisse befinden sich im Anhang in den Tabellen B.4 bis B.6.

Bereits nach einer kurzen Testphase waren alle Probanden in der Lage, beide Zustandsautomaten zu bedienen. Die erreichten Genauigkeiten und ITR sind bei beiden Zustandsautomaten ungefähr gleich. Dies wird anhand der in den Abbildungen 4.19a und 4.19b dargestellten Verteilungen beider Parameter deutlich. Den Verteilungen liegen alle ermittelten Genauigkeiten und ITR zugrunde. Überwiegend erreichten die Probanden Genauigkeiten von 100 %. Durch einige wenige Ausreißer liegen die Mittelwerte leicht darunter. Beim 1-Tupel Zustandsautomaten erreichten die Probanden im Mittel eine Genauigkeit von  $98,19 \pm 3,79$  %. Die mittlere Genauigkeit des 2-Tupel




Abbildung 4.19.: Verteilungen der Genauigkeiten (a), der ITR (b) und der benötigten Zeiten zur Absolvierung der vier Aufgaben (c) unter Nutzung des 1- und 2-Tupel Zustandsautomaten. Den Verteilungen liegen alle ermittelten Messwerte zugrunde.

Zustandsautomaten liegt bei  $98,93 \pm 4,07$  %. Die leicht höhere mittlere Genauigkeit des 2-Tupel Zustandsautomaten ist dadurch zu erklären, dass für seine Nutzung weniger Kommandos notwendig sind als für den 1-Tupel Zustandsautomaten. Hierdurch ist die Wahrscheinlichkeit für das Auftreten eines Fehlers geringer. Bei beiden Zustandsautomaten liegen 75 % aller ITR über 30 bits/min. Im Mittel erreichten die Probanden mit dem 1-Tupel Zustandsautomaten eine ITR von  $38,04 \pm 11,11$  bits/min und mit dem 2-Tupel Zustandsautomaten von  $37,08 \pm 10,59$  bits/min. Aufgrund des wiederholt hintereinander durchzuführenden Zurück-Kommandos bei der Verwendung des 1-Tupel Zustandsautomaten, ist bei diesem auch die ITR häufig etwas höher.

#### 4.6. Vergleich der Umschalt- und Steuermodalitäten und der beiden Zustandsautomaten

---

In der Abbildung 4.19c sind die Verteilungen der von allen Probanden benötigten Zeiten zur Absolvierung der vier Aufgaben zu sehen. Die gestrichelten Linien zeigen das jeweilige Optimum an. Im optimalen Fall wird angenommen, dass der Nutzer nach jeder vom System vorgegebenen Ruhepause von zwei Sekunden ein Kommando sendet. Beim 2-Tupel Zustandsautomaten sind immer zwei Kommandos für den Sprung in eine Steuerungsgruppe notwendig und ein Kommando für den Rücksprung in den Aktivzustand. Somit sind für jeden Wechsel der Steuerungsgruppe drei Kommandos notwendig. Die optimalen Zeiten der ersten drei Aufgaben sind daher identisch. Lediglich für die letzte Aufgabe wird ein zusätzlicher Wechsel verlangt. Der 1-Tupel Zustandsautomat benötigt für den Wechsel der Steuerungsgruppe häufig eine unterschiedliche Anzahl an Kommandos und somit auch unterschiedliche Zeiten.

Insgesamt kommen nur wenige Messungen in die Nähe der optimalen Werte. Bei allen Aufgaben benötigten die Probanden mit dem 2-Tupel Zustandsautomaten deutlich weniger Zeit als mit dem 1-Tupel Zustandsautomaten. Der zeitliche Unterschied ist bei den ersten drei Aufgaben besonders deutlich. Hier liegen beim 1-Tupel Zustandsautomaten 75 % der Werte zwischen ca. 19 und 37 s und beim 2-Tupel Zustandsautomaten zwischen ca. 11 und 22 s. Da die drei Achsen im 1-Tupel Zustandsautomaten nah beieinander liegen, ist der zeitliche Unterschied bei der vierten Aufgabe nicht so groß, wie bei den anderen Aufgaben. Aber auch hier ist die Bearbeitungszeit mit dem 2-Tupel Zustandsautomaten geringer. So liegen 75 % der Messwerte des 1-Tupel Zustandsautomaten zwischen ca. 27 und 47 s und des 2-Tupel Zustandsautomaten zwischen ca. 20 und 33 s.

Aufgrund der geringeren Anzahl an benötigten Kommandos und der damit verbundenen geringeren Bearbeitungszeit, wurde der 2-Tupel Zustandsautomat für die Roboterarmsteuerung ausgewählt. Die Probanden bevorzugten den 2-Tupel Zustandsautomaten aus den genannten Gründen. Die Kommandosequenzen empfanden die Probanden als leicht zu merken. Außerdem gaben die Probanden an, dass sie sich bei der Verwendung des 2-Tupel Zustandsautomaten nur auf das akustische Feedback konzentrieren mussten.

Für die Verwendung des 1-Tupel Zustandsautomaten war die visuelle Darstellung auf dem Monitor unerlässlich, da die Länge der für einen Wechsel der Steuerungsgruppe benötigten Kommandosequenz variierte.

## **4.7. Test der schrittweisen Roboterarmsteuerung**

In dieser Studie wurde die schrittweise Roboterarmsteuerung, anhand einer Pick-and-Place-Anwendung, getestet und unter objektiven und subjektiven Kriterien evaluiert. Eine Übersicht über das dabei verwendete System befindet sich im Abschnitt 4.1. Die Probanden nutzten das in Abschnitt 4.2 beschriebene frequenzbasierte SSVEP-BCI als Umschalt- und Steuermodalität. Zur Stimulation wurden die LEDs des in Abschnitt 3.1 beschriebenen sBCI-Helms verwendet. Mit dem 2-Tupel Zustandsautomaten, aus Abschnitt 4.4, standen den Probanden alle Kommandos zur Robotersteuerung zur Verfügung, die für eine Translation, eine Rotation sowie ein Öffnen und ein Schließen des Greifers benötigt wurden. Das verwendete BCI-Paradigma und der eingesetzte Zustandsautomat wurden im vorherigen Abschnitt am besten bewertet und daher für die Roboterarmsteuerung ausgewählt. Für die Regelung des Roboterarmes LWA 3 und des Greifers PG70 des Unternehmens Schunk wurde die in Abschnitt 4.5 beschriebene Implementierung eingesetzt.

### **4.7.1. Versuchsteilnehmer**

Zwei weibliche und acht männliche Probanden nahmen an diesem Experiment teil. Das Alter der Probanden lag zwischen 18 und 33 Jahren, mit einem Durchschnittsalter von  $28,20 \pm 4,61$  Jahren. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwands-

entschädigung. Der Ethikausschuss der Universität Bremen erteilte die Genehmigung zur Durchführung des Experimentes. Vor dem Experiment erhielten die Probanden eine Informationsbroschüre und unterzeichneten eine Einverständniserklärung.

Die Versuche fanden in einem Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Dieses Labor besaß keine besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor dem 150 cm entfernten Roboterarm. Somit befanden sich die Probanden außerhalb des Arbeitsbereichs des Roboters.

### 4.7.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Das SSVEP-BCI nutzte 8 Kanäle ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

### 4.7.3. Versuchsprotokoll

Vor dem Experiment mussten die Probanden für das frequenzbasierte SSVEP-BCI dieselbe Kalibrierung wie beim Vergleich der Umschalt- und Steuermodalitäten (Abschnitt 4.6) durchführen. Alle vorherigen Einstellungen wurden in diesem Versuch übernommen.

Im Anschluss an die Kalibrierung erhielten die Probanden eine Einweisung in die BCI-basierte Steuerung des Roboterarmes. Weiterhin konnten die Probanden den Roboter für ungefähr 10 Minuten frei steuern, um sich mit der Steuerung vertraut zu machen.

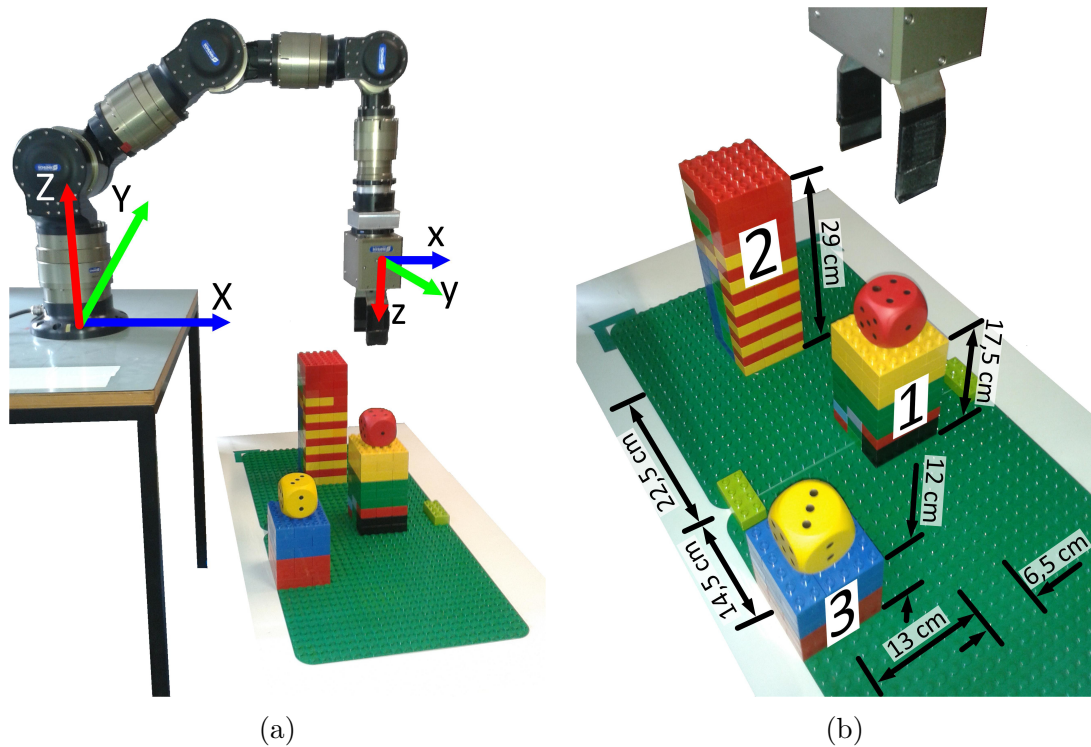


Abbildung 4.20.: Experimenteller Aufbau für den Test der BCI-basierten Roboterarmsteuerung. (a) Der Roboterarm mit seinem Basis- und Greiferkoordinatensystem aus der Perspektive des Probanden betrachtet. (b) Detailansicht des Aufbaus mit den wichtigsten Bemaßungen.

In der Abbildung 4.20a ist der experimentelle Aufbau aus der Sicht des Probanden zu sehen. Aus dieser Perspektive stimmen die bebilderten Bewegungen des Roboterarmes aus der Kommandoübersicht des 2-Tupel Zustandsautomaten (Tabelle 4.1) mit den realen Bewegungen des Greifers innerhalb des Basiskoordinatensystems überein. Der Greifer befindet sich in dieser Abbildung in seiner Anfangspose. Drei Türme aus Lego wurden auf einem niedrigen Tisch rechts unterhalb des auf einem Tisch montierten Roboters platziert. Eine Detailansicht des Aufbaus, mit den Höhenangaben der Türme und den Distanzen zwischen den Zentren der Türme, befindet sich in der Abbildung 4.20b.

Die Probanden erhielten die Aufgabe, den Würfel aus Schaumgummi vom Turm Nr. 1 zu greifen und auf dem Turm Nr. 2 zu platzieren (erste Teilaufgabe). Anschließend mussten die Probanden einen weiteren Würfel vom Turm Nr. 3 greifen und auf dem Turm



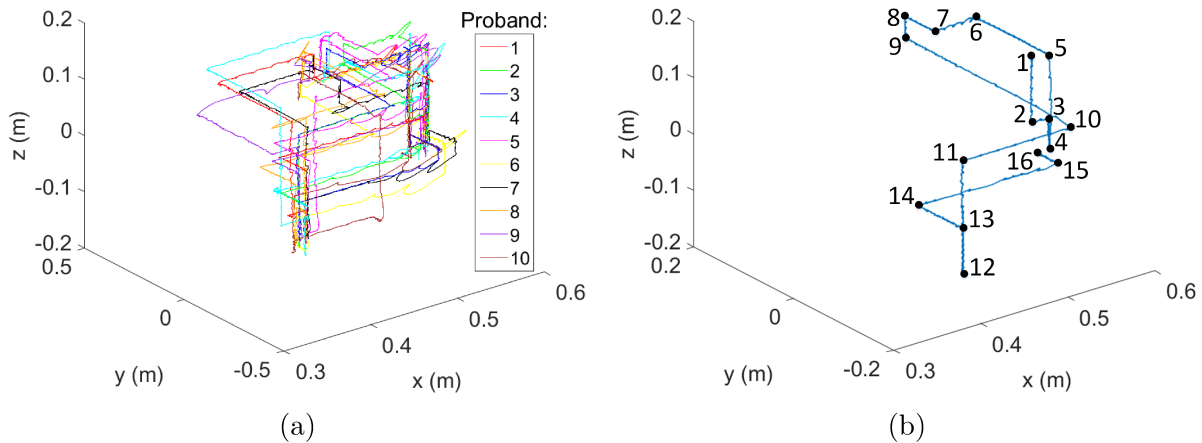


Abbildung 4.21.: Die Trajektorien zur Bearbeitung der Pick-and-Place-Aufgabe von allen Probanden (a) und von einem Probanden (b). Bei der einzelnen Trajektorie wird die zeitliche Abfolge anhand der Nummerierung gezeigt.

Nr. 1 platzieren (zweite Teilaufgabe). Beide Teilaufgaben mussten die Probanden direkt hintereinander und so schnell wie möglich bearbeiten. Zur Bearbeitung der gesamten Aufgabe waren sowohl translatorische als auch rotatorische Bewegungen notwendig. Jeder Proband musste die gesamte Aufgabe 2 Mal durchführen. Alle Versuche wurden überwacht und ein Notausschalter stand für unvorhersehbare Ereignisse zur Verfügung.

#### 4.7.4. Evaluierung

Alle Teilnehmer der Studie waren in der Lage, über die entwickelte Schnittstelle, den Roboter zu steuern und die gestellten Aufgaben vollständig zu bearbeiten. In der Abbildung 4.21a sind die während des zweiten Versuchs gefahrenen Trajektorien von allen 10 Probanden zu sehen. Die Abbildung 4.21b zeigt exemplarisch die gefahrene Trajektorie von einem Probanden. Anhand der Nummerierung ist der zeitliche Verlauf der Trajektorie ersichtlich. Zum Zeitpunkt 4 wurde der erste Würfel gegriffen und zum Zeitpunkt 9 auf dem Turm Nr. 2 platziert. Der zweite Würfel wurde zum Zeitpunkt 12 gegriffen und zum Zeitpunkt 16 auf dem Turm Nr. 1 platziert.




Abbildung 4.22.: Die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der ersten und zweiten Teilaufgabe.

Um die Schnittstelle zu evaluieren, wurden sowohl subjektive als auch objektive Messungen gesammelt. Die Bearbeitungszeit der Aufgabe und die dabei benötigte Anzahl an Umschalt- und Steuerkommandos dienen der objektiven Evaluierung. Um eine subjektive Evaluierung zu ermöglichen, beantworteten die Probanden den NASA Task Load Index (NASA-TLX)-Fragebogen [68] und einen selbst entwickelten Fragebogen.

#### 4.7.4.1. Objektive Evaluierung

Um eine minimale Referenzzeit spezifizieren zu können, wurden die kürzeste Trajektorie und die dafür notwendige Anzahl an Kommandos ermittelt. Für die erste Teilaufgabe sind mindestens 72 Kommandos und für die zweite Teilaufgabe 69 Kommandos notwendig. Da nach jedem Kommando eine Ruhephase von 2 s folgt, beträgt die minimale Zeit für die erste Teilaufgabe 2,40 Minuten und für die zweite Teilaufgabe 2,30 Minuten.

Die Abbildung 4.22 zeigt die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der beiden Teilaufgaben. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle B.7. Im Mittel benötigten die Probanden  $8,44 \pm 2,93$  Minuten

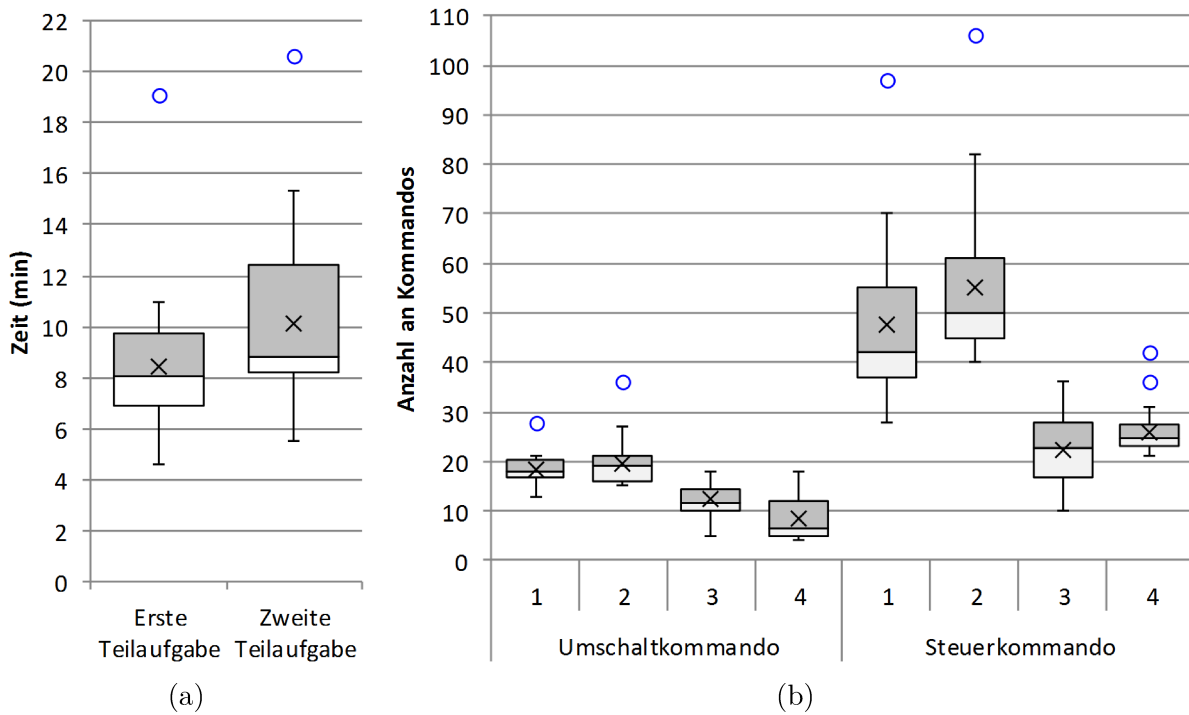


Abbildung 4.23.: Verteilungen der benötigten Zeiten für die erste und die zweite Teilaufgabe (a) und der benötigten Umschalt- und Steuerkommandos (b). Den Verteilungen liegen alle ermittelten Werte zugrunde.

für die erste Teilaufgabe und  $10,11 \pm 3,47$  Minuten für die zweite Teilaufgabe. Am schnellsten bearbeitete Proband 9 die erste Teilaufgabe (4,99 Minuten) und Proband 1 die zweite Teilaufgabe (6,10 Minuten). Beide Probanden konnten sehr schnell mit dem SSVEP-BCI Kommandos erzeugen und erzielten bereits beim Vergleich der Umschalt- und Steuermodalitäten (Abschnitt 4.6) sehr hohe ITR. Die anderen Probanden erzielten geringere Kommunikationsgeschwindigkeiten, wodurch deren Bearbeitungszeiten etwas höher liegen. Die Probanden 4 und 10 benötigten auffällig viel Zeit zur Erzeugung von Kommandos. Trotzdem waren beide Probanden in der Lage, den Roboterarm akkurat zu steuern und beide Durchläufe erfolgreich zu absolvieren.

In der Abbildung 4.23a sind die Verteilungen aller gemessenen Zeiten, für die erste und zweite Teilaufgabe, zu sehen. Die minimale Bearbeitungszeit der ersten Teilaufgabe liegt bei 4,56 Minuten und die der zweiten Teilaufgabe bei 5,49 Minuten. Mit Ausnahme

eines Ausreißers liegen alle Zeiten der ersten Teilaufgabe unter 10,99 Minuten und 75 % aller Werte unter 9,74 Minuten. Für die zweite Teilaufgabe benötigten die Probanden etwas mehr Zeit als für die erste Teilaufgabe. Hier liegen fast alle Zeiten unter 15,36 Minuten und 75 % aller Werte unter 12,46 Minuten. Jedoch liegen 50 % der Zeiten unter 8,81 Minuten.

Abbildung 4.23b zeigt die Verteilungen der für beide Teilaufgaben benötigten Umschalt- und Steuerkommandos. Den Verteilungen liegen alle ermittelten Werte zugrunde. Wie in dem Diagramm zu sehen, wurden die Umschaltkommandos 1 und 2 am häufigsten verwendet. Da für die Bearbeitung der Aufgaben mehr Translationen als Rotationen erforderlich sind und das zweite Tupel-Kommando für eine Translation immer eine 1 oder 2 sein muss, ist das Ergebnis zu erwarten gewesen. Am dritthäufigsten wurde das Kommando 3 für Rotationsbewegungen und ein Umschalten in die z-Achse benutzt. Das Umschaltkommando 4 wurde überwiegend für den Wechsel in die Gruppe des Greifers generiert, wodurch dessen Anzahl am geringsten ist.

Auch die Steuerkommandos 1 und 2 wurden am häufigsten erzeugt. Dieses Ergebnis war zu erwarten, da beide Kommandos eine schrittweise Bewegung in positiver oder negativer Achsenrichtung bewirken. Die Anzahl des Steuerkommandos 3, zur Veränderung der Schrittweite, liegt zwischen 10 und 36 und variiert stark von Nutzer zu Nutzer. Hierdurch variieren auch die benötigten Schritte bzw. die Anzahl der Steuerkommandos 1 und 2. Die Anzahl des Steuerkommandos 1 liegt zwischen 28 und 70 und die des Steuerkommandos 2 zwischen 40 und 82. Das zum Verlassen einer Gruppe benötigte Steuerkommando 4 gibt Aufschluss darüber, wie oft die Probanden umschalten mussten. Die Anzahl liegt zwischen 21 und 31 und variiert je nach gewählter Trajektorie.

Einen Vergleich der gesamten Bearbeitungszeiten, für den ersten und den zweiten Versuch, liefern die Verteilungen in der Abbildung 4.24a. Den Verteilungen liegen alle ermittelten Zeiten zugrunde. Mit Ausnahme von zwei Probanden konnten sich alle




Abbildung 4.24.: Verteilungen der gesamten Bearbeitungszeiten (a) und der benötigten Steuerkommandos (b) für den ersten und den zweiten Versuch. Den Verteilungen liegen alle ermittelten Werte zugrunde.

Teilnehmer zeitlich verbessern. Die Zeiten des ersten Versuchs liegen zwischen 12,63 und 31,62 Minuten und die des zweiten Versuchs zwischen 11,28 und 20,87 Minuten. Durchschnittlich verbesserten sich die Probanden um 3,28 Minuten.

Veränderungen der benötigten Anzahl an Steuerkommandos zeigen die Verteilungen in der Abbildung 4.24b. Den Verteilungen liegen alle ermittelten Werte zugrunde. Beim 2. Versuch benutzten die Probanden etwas häufiger das Steuerkommando 3, um die Schrittweite zu verändern. Durch die Wahl von größeren Schrittweiten reduzierte sich die Anzahl der benötigten Steuerkommandos 1 und 2 zur Ausführung der Schritte. Bei dem Steuerkommando 4 ist keine große Veränderung ersichtlich. Die Probanden wählten in beiden Durchläufen eine ähnliche Trajektorie und konnten die Anzahl der Steuerungsgruppenwechsel nicht reduzieren.




Abbildung 4.25.: Verteilungen der subjektiven Bewertungen anhand des NASA-TLX-Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.

#### 4.7.4.2. Subjektive Evaluierung

In der Abbildung 4.25 befinden sich die Ergebnisse der subjektiven Evaluierung anhand des NASA-TLX-Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde. Der Wertebereich des NASA-TLX-Fragebogens reicht von 0 (sehr gering) bis 100 (sehr hoch) für die Bewertung der mentalen, physischen und zeitlichen Anforderung sowie der Anstrengung und der Frustration. Die Leistungseinschätzung des Nutzers kann zwischen 0 (perfekt) und 100 (Misserfolg) liegen.

Obwohl die Steuerung in diskreten Schritten und durch die Aufmerksamkeitsverschiebung auf blinkende LEDs erfolgte, wurde die mentale, physische und zeitliche Anforderung der Aufgabe als nicht sehr hoch empfunden. Die Mehrheit der Probanden bewertete alle drei Parameter mit einem Wert unter 40. Probanden, die sehr lange benötigten, um ein Kommando zu erzeugen, bewerteten die Anforderungen, die Anstrengung und die Frustration deutlich höher als Probanden mit einer hohen Kommunikationsgeschwindigkeit. Außerdem bewerteten sie ihre Leistung negativer. Überwiegend empfanden die Probanden die Aufgabe nicht als frustrierend und bewerteten ihre Leistung positiv. Aufgrund der schrittweisen Steuerung, mussten die Probanden sehr viele Kommandos

senden und empfanden daher die Steuerung als sehr anstrengend.

Der selbst entwickelte Fragebogen nutzt die Likert-Skala [105], die von 1 (trifft gar nicht zu) bis 5 (trifft ganz zu) reicht. Die Ergebnisse dieser subjektiven Evaluierung befinden sich in der Abbildung 4.26. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.

Die Steuerungsgruppen zur Veränderungen der Pose des Greifers wurden als sehr intuitiv bewertet. Hier konnten sich alle Probanden vorstellen, welche Bewegung der Roboter ausführen wird, wenn sie ein Kommando senden. Bei der Gruppe des Greifers wählten einige Probanden häufig das falsche Kommando zum Öffnen oder Schließen und bewirkten somit die gegensätzliche Aktion. Lediglich ein Proband hatte Schwierigkeiten, die Pose des Roboterarmes richtig einzuschätzen. Ein präzises Greifen war für alle Probanden möglich.

Bereits bei der objektiven Evaluierung konnte festgestellt werden, dass die Kommunikationsgeschwindigkeit von Nutzer zu Nutzer sehr unterschiedlich ist und sich auf die Bearbeitungszeit der gestellten Aufgabe auswirkt. Dieser Umstand besitzt auch eine Auswirkung auf die subjektive Bewertung. Einige Probanden konnten sehr schnell SSVEP-Antworten erzeugen und empfanden es daher als leicht, Kommandos zu senden. Hingegen benötigten andere Probanden viel Zeit für die Erzeugung von SSVEP-Antworten und empfanden das Senden von Kommandos deshalb als schwierig. Da die beiden Steuerkommandos 1 und 2 besonders häufig verwendet wurden, erhielten diese die schlechtesten Bewertungen.

Die Schrittweiten aller Bewegungen beurteilten die Probanden als ausreichend, um für die gestellte Aufgabe eine präzise Bewegung des Roboterarmes zu ermöglichen. Für Aufgaben, die sehr präzise Bewegungen benötigen, seien jedoch kleinere Schrittweiten oder eine kontinuierliche Geschwindigkeit notwendig. Ein Umschalten zwischen den Steuerungsgruppen ist mit dem 2-Tupel Zustandsautomaten nach nur drei Kommandos möglich und wurde als schnell und einfach bewertet.




Abbildung 4.26.: Verteilungen der subjektiven Bewertungen anhand des selbst entwickelten Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.



## Kapitel 5.

# Geschwindigkeitsbasierte Steuerung eines Roboterarmes über ein hybrides BCI

In diesem Kapitel wird ein System zur geschwindigkeitsbasierten Steuerung eines Roboterarmes über ein hybrides BCI vorgestellt. Im Gegensatz zu der schrittweisen Roboterarmsteuerung des vorherigen Kapitels, führt der Roboter eine kontinuierliche Bewegung, anstelle von diskreten Schritten, aus. Nach einem Sprung in eine Steuerungsgruppe bewegt sich der Greifer mit einer konstanten Geschwindigkeit solange in eine Richtung, bis ein Kommando für einen Richtungswechsel oder ein Stopp-Kommando gesendet wird. Ein Vorteil, im Vergleich zur schrittweisen Roboterarmsteuerung, besteht darin, dass der Nutzer weniger Kommandos senden muss und dadurch weniger beansprucht wird. Weiterhin ist mit der Steuerung ein viel präziseres Greifen möglich. Wie bereits bei der schrittweisen Steuerung, werden das frequenzbasierte SSVEP-BCI (Abschnitt 4.2) und der 2-Tupel Zustandsautomat (Abschnitt 4.4) zum Umschalten zwischen den verschiedenen Steuerungsgruppen und zur Steuerung innerhalb einer Gruppe verwendet. Ebenfalls lässt sich der visuelle Stimulator über eine Bewegungsvorstellung ein- und ausschalten. Dafür wird das ERD/ERS-BCI aus Abschnitt 3.2.2 verwendet. Weiterhin wird dieselbe Implementierung der Roboterregelung verwendet (Abschnitt 4.5). Diese empfängt die Steuerkommandos und führt anstelle eines diskreten Schritts eine kontinuierliche Bewegung aus. Ein Stoppen des Roboterarmes kann mit dem SSVEP-BCI erfolgen oder über

ein Schließen der Augen. Beim Schließen der Augen entstehen Augenartefakte im EEG und bei einem Geschlossenhalten der Augen kommt es zu einem Anstieg der Leistung im Alphafrequenzbereich. Durch die Detektion von Augenartefakten und Alphawellen wird ein Stoppen des Roboters erreicht.

Zu Beginn dieses Kapitels werden die Anforderungen an die Roboterarmsteuerung beschrieben und eine Übersicht über das System geliefert. Die Übersicht stellt dar, über welche Komponenten die Steuerung verfügt und wie die Komponenten zusammenwirken. Anschließend erfolgt eine Beschreibung der beiden Stoppmodalitäten Alphawellen und Augenartefakte. Danach folgt eine Vergleichsstudie der Stoppmodalitäten. Zusätzlich zu den bereits genannten Systemen wurde das ERP-BCI aus Kapitel 6 getestet. Dieses detektiert ereigniskorrelierte Potenziale, die entstehen, sobald der Greifer des Roboterarmes die Zielposition erreicht. Anhand der Studie wird gezeigt, welche Modalität am geeignetsten für einen Stopp des Roboterarmes an der Zielposition oder in Gefahrensituationen ist und welche Geschwindigkeiten zu wählen sind. Zum Schluss wird die Steuerung anhand einer Pick-and-Place-Aufgabe getestet und unter objektiven und subjektiven Kriterien evaluiert. Im Rahmen der objektiven Evaluierung findet ein Vergleich mit der schrittweisen Roboterarmsteuerung statt.

## **5.1. Systemanforderungen und -übersicht**

Die im vorherigen Kapitel beschriebene Schnittstelle ermöglicht die schrittweise Steuerung eines Roboterarmes. Das System kann über diskrete Kommandos den Greifer eines Roboterarmes in jede Position und Orientierung bringen. Der Nachteil dieser Art der Steuerung besteht darin, dass sich der Roboter nur mit vorher festgelegten Schrittweiten fortbewegen kann. Eine zu geringe Anzahl an Schrittweiten ermöglicht keine präzise Steuerung und zu viele Schrittweiten führen zu langen Auswahlzeiten. Außerdem muss der Nutzer des Systems viele Kommandos senden und wird dadurch von der Steuerung stark beansprucht. Um die genannten Nachteile zu beseitigen, wird bei dem Ansatz dieses

Kapitels der Greifer mit festgelegten Geschwindigkeiten bewegt. Durch unterschiedlich große Geschwindigkeiten ist eine präzisere und schnellere Steuerung möglich als mit diskreten Schrittweiten. Der Anwender muss die Bewegung nur starten und stoppen und wird so weniger beansprucht.

Sowohl die Anforderungen an die Schnittstelle als auch die Umsetzung des Systems unterscheiden sich nur geringfügig von der schrittweisen Steuerung. Die Systemanforderungen und -übersicht der schrittweisen Steuerung befinden sich im Abschnitt 4.1. Zusätzlich zu den Anforderungen der anderen Schnittstelle, muss der Nutzer in der Lage sein, den Roboterarm zu jeder Zeit zum Stoppen bringen zu können.

Um dem Anwender die Gelegenheit zu geben, seine Konzentration von einer LED abzuwenden und eine Bewegungsvorstellung zu beenden, findet weiterhin eine Ruhepause von 2 s nach dem Senden eines Kommandos statt. Im Unterschied zu der schrittweisen Steuerung erfolgt bei den Steuerkommandos diese Ruhepause nur zwischen zwei identischen Kommandos. Dies ermöglicht ein schnelleres Eingreifen in die Steuerung seitens des Nutzers.

Wird mit dem 2-Tupel Zustandsautomaten eine Steuerungsgruppe ausgewählt, führt das System unmittelbar die Bewegung in die angegebene Richtung aus. Jeder Wechsel der Steuerungsgruppe setzt die Geschwindigkeit auf den niedrigsten Wert. Ein Senden der Steuerkommandos 1 und 2 führt zu einer Bewegung in positiver bzw. negativer Achsenrichtung. Führt der Roboter eine Bewegung in die angegebene Richtung aus, so führt ein wiederholtes Senden zu einem Stopp. Über das Steuerkommando 3 lässt sich die Geschwindigkeit in einem Ringdurchlauf verändern. Der Greifer kann sich mit den Geschwindigkeiten 7, 14 und 28 mm/s fortbewegen. Im Rahmen einer Vergleichsstudie der Stoppmodalitäten wurden diese Geschwindigkeiten als am geeignetsten ausgewählt (siehe Abschnitt 5.4). Das Steuerkommando 4 führt zu einem Verlassen der Steuergruppe und, falls noch nicht zuvor geschehen, zu einem Stoppen des Roboters. Unmittelbar nach dem Starten einer Bewegung ist ein schnelles Stoppen nur über das Steuerkommando 4 oder über ein Schließen der Augen möglich. Das Schließen der Augen wird anhand von

Artefakten im EEG und über das Auftauchen von Alphawellen detektiert. In Kombination ermöglichen beide Modalitäten ein schnelles und sicheres Stoppen des Roboters. Beide Modalitäten wurden, im Rahmen der bereits erwähnten Vergleichsstudie, als am geeignetsten ausgewählt (siehe Abschnitt 5.4).

Die Regelung empfängt während der auszuführenden Bewegung permanent Kommandos vom Zustandsautomaten. Solange die Regelung Kommandos empfängt, sorgt sie für eine kontinuierliche Bewegung des Greifers. Dafür wird lediglich die inverse Kinematik verwendet und nicht, wie bei der schrittweisen Steuerung, der Pfadplaner. Die inverse Kinematik ermittelt in kurzen Zeitabständen die anzufahrenden Gelenkwinkel für sehr kleine Veränderungen der Pose des Greifers. Mit dem Pfadplaner ließe sich keine konstante Geschwindigkeit des Greifers erreichen, da für die Planung von Trajektorien zu viel Rechenzeit benötigt wird.

## **5.2. Alphawellen als Stopppmodalität**

Dieser Abschnitt beschreibt das asynchrone Alphawellen-BCI, das zum Stoppen des Roboterarmes verwendet wird. Alphawellen können zuverlässig und willentlich vom Menschen beeinflusst werden. Solange der Anwender der Roboterarmsteuerung seine Augen geöffnet hält und sich auf die ausgeführte Bewegung des Greifers konzentriert, treten nur geringfügig Alphawellen auf. Sobald der Anwender die Augen schließt, ist ein verstärktes Auftreten von Alphawellen die Folge. Die Detektion einer erhöhten Aktivität im Alphafrequenzbereich bewirkt einen Stopp des Roboters. Der Nutzer kann somit über ein Geschlossenhalten der Augen den Greifer an der Zielposition und in Gefahrensituationen zum Stoppen bringen.

Zu Beginn dieses Abschnittes erfolgt eine Beschreibung der Signalverarbeitung, die anhand von Alphawellen geöffnete und geschlossene Augen detektiert. Zum Schluss wird die Kalibrierung beschrieben, die Daten für den zu trainierenden Klassifikator aufnimmt.

Kalibrierungsergebnisse von 17 Probanden dienen der Evaluierung des Alphawellen-BCIs.

### **5.2.1. Signalverarbeitung**

In anderen Arbeiten erfolgt die Detektion von Alphawellen über eine Fast Fourier Transformation (FFT). Sobald die Amplituden im relevanten Frequenzbereich einen festgelegten Schwellwert überschreiten, wird ein Geschlossenhalten der Augen klassifiziert. Andernfalls wird ausgegeben, dass die Augen geöffnet sind. Diese Art der Klassifikation benötigt jedoch einen zu bestimmenden Schwellwert und liefert nicht für jeden Probanden eine hohe Klassifikationsgenauigkeit [78].

Die Signalverarbeitung dieser Dissertation nutzt, in einem ersten Schritt, eine Bandpassfilterung der EEG-Signale im zu betrachtenden Alpha-Frequenzband (8-12 Hz). Nach der Filterung findet die Extraktion von Merkmalen statt. Als Merkmale werden Kovarianzmatrizen verwendet, da diese die räumliche Information der Signale beinhalten. Eine mögliche Verarbeitung der Matrizen bestünde in ihrer Vektorisierung und der Verwendung von herkömmlichen Verfahren des maschinellen Lernens (z.B. SVM, LDA, NN). Diese Option entfällt jedoch, da es sich bei Kovarianzmatrizen um symmetrisch positiv-definite (SPD)-Matrizen handelt und diese nicht im notwendigen Vektorraum liegen (z.B. ist die Negation einer positiv-definiten Matrix nicht länger eine positiv-definite Matrix) [54]. Die in dieser Arbeit ausgewählten Klassifikatoren Minimum Distance to Riemannian Mean (MDRM) und Filter Geodesic Minimum Distance to Riemannian Mean (FGMDRM) sind in der Lage, eine Klassifikation direkt anhand von Kovarianzmatrizen im Sensorraum vorzunehmen. Sie wurden bereits zur Klassifikation von Bewegungsvorstellungen [10, 11, 12], ereigniskorrelierten Potenzialen [13] und SSVEPs [87] eingesetzt. Die Klassifikatoren benötigen für jede Klasse einen Satz an Trainingsdaten mit bekannter Klassenzugehörigkeit, die im Rahmen einer Kalibrierung aufgenommen wurden. Die Klassifikatoren besitzen, neben ihrer direkten Verwendung der Kovarianz-

matrizen und ihrer Verwendung für verschiedene Paradigmen, den Vorteil, dass keine Parameter zu bestimmen sind.

#### 5.2.1.1. Signalvorverarbeitung und Merkmalsextraktion

Alphawellen liegen in einem Frequenzbereich von 8 bis 12 Hz. Im Rahmen der Vorverarbeitung werden in diesem Intervall zuerst die Signale einer Bandpassfilterung unterzogen. Dafür wird ein Butterworth-Bandpassfilter fünfter Ordnung eingesetzt.

Im nächsten Schritt wird für jedes Datensegment (engl. Trial) die Kovarianzmatrix geschätzt.  $\mathbf{x}_i \in \mathbb{R}^{C \times 1}$  sind die von  $C$  Elektroden aufgenommenen Datenpunkte zum Zeitpunkt  $i$ . Das Datensegment  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N] \in \mathbb{R}^{C \times N}$  beinhaltet  $N$  Datenpunkte von jeweils  $C$  Elektroden.

Ist  $N \gg C$ , wird die Kovarianzmatrix empirisch geschätzt (engl. Sample Covariance Matrix (SCM)). Die SCM ist definiert als [87]:

$$\Sigma_{\text{scm}} = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (5.1)$$

mit  $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \in \mathbb{R}^{C \times 1}$ .

Für den Fall  $N \approx C$  liefert die SCM keine gute Schätzung der Kovarianzmatrix. Da die Anzahl unbekannter Parameter größer ist als die zur Verfügung stehenden Datenpunkte, werden große Eigenwerte der Kovarianzmatrix zu groß und kleine Eigenwerte zu klein geschätzt. Um diesen systematischen Fehler zu kompensieren, wird die Kovarianzmatrix wie folgt geschätzt [23]:

$$\Sigma_{\text{shrink}} = (1 - \gamma)\Sigma_{\text{scm}} + \gamma v \mathbf{I} \quad (5.2)$$

mit dem Einstellungsparameter  $\gamma \in [0, 1]$ , dem mittleren Eigenwert  $v = \frac{\text{Spur}(\Sigma_{\text{scm}})}{C}$  und der Einheitsmatrix  $\mathbf{I}$ . Führt man nun eine Eigenwertzerlegung der Matrix  $\Sigma_{\text{scm}} = \mathbf{V}\mathbf{D}\mathbf{V}^T$  durch und setzt diese in Gleichung 5.2 ein, so ergibt sich:

$$\Sigma_{\text{shrink}} = (1 - \gamma)\mathbf{V}\mathbf{D}\mathbf{V}^T + \gamma v \mathbf{V}\mathbf{V}^T = \mathbf{V}((1 - \gamma)\mathbf{D} + \gamma v \mathbf{I})\mathbf{V}^T \quad (5.3)$$

mit den Eigenvektoren  $\mathbf{V}$  und den dazugehörigen Eigenwerten in der Diagonalmatrix  $\mathbf{D}$ . Die Eigenvektoren der Kovarianzmatrizen  $\Sigma_{\text{scm}}$  und  $\Sigma_{\text{shrink}}$  sind somit identisch, jedoch werden extreme Eigenwerte (groß oder klein) in Richtung des mittleren Eigenwertes modifiziert (geschrumpft oder angehoben). Der optimale Wert für  $\gamma$  wird, wie in der Arbeit [23] beschrieben, mit einer analytischen Methode ermittelt.

### 5.2.1.2. Klassifikation

Die in diesem Abschnitt beschriebenen Klassifikatoren MDRM und FGMDRM benötigen  $M$  Kovarianzmatrizen  $\Sigma = [\Sigma_1, \dots, \Sigma_M]$  als Trainingsdaten. Von jeder dieser Kovarianzmatrizen muss die Zugehörigkeit zu einer der  $K$  Klassen bekannt sein. Die Aufgabe der Klassifikation besteht darin, eine Kovarianzmatrix  $\Sigma_x$ , mit unbekannter Klassenzugehörigkeit, einer der  $K$  Klassen zuzuordnen. Im Falle der Klassifikation von geöffneten und geschlossenen Augen ist  $K = 2$ . Unter Verwendung der Trainingsdaten wird für jede der  $K$  Klassen zunächst eine gemittelte Kovarianzmatrix berechnet. Daraufhin wird die Kovarianzmatrix  $\Sigma_x$  der Klasse zugeordnet, dessen Mittel am nächsten liegt. Um dieses Verfahren realisieren zu können, wird eine Distanzfunktion (Metrik) und die dazugehörige Funktion zur Berechnung des Mittels benötigt.

Wie in der Literatur bekannt, liefern das arithmetische Mittel und die euklidische Distanz, im Vergleich zum Riemannschen Mittel und zur Riemannschen Distanz, eine geringere Klassifikationsgenauigkeit [11]. In der Abbildung 5.1 ist ein Vergleich beider Metriken zu sehen. Hierfür wurden zunächst Kalibrierungsdaten, für die beiden Klassen „geschlossene Augen“ und „geöffnete Augen“, aufgenommen (siehe Abschnitt 5.2.2).

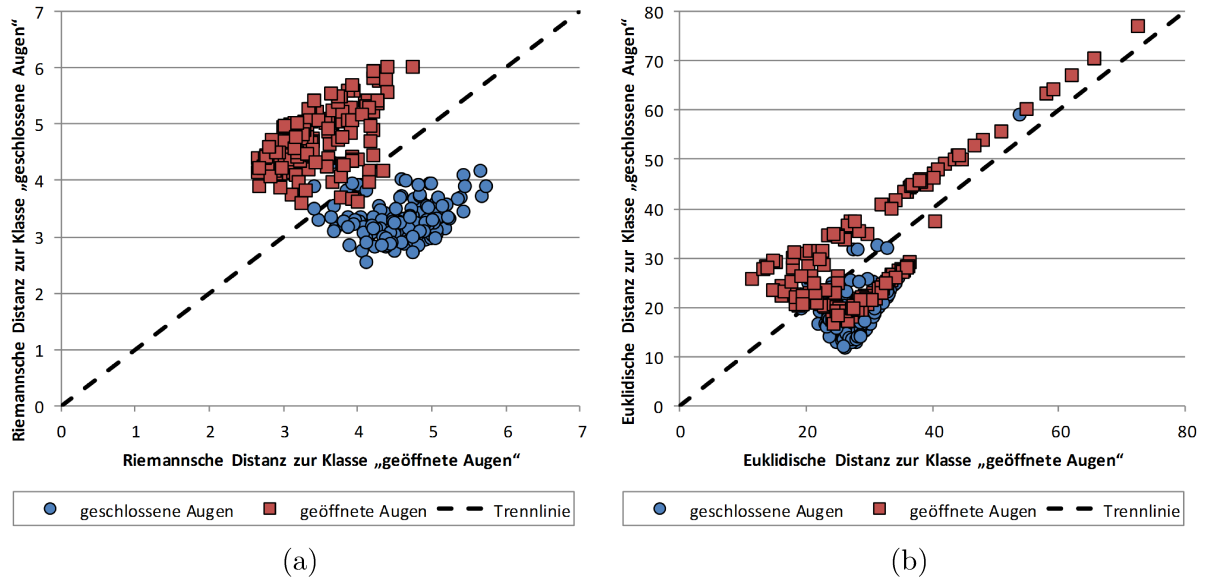


Abbildung 5.1.: Vergleich von zwei Metriken zur Klassifikation von geschlossenen Augen und geöffneten Augen anhand von Alphawellen. Das Riemannsche Mittel und die Riemannsche Distanz (a) ermöglichen, im Vergleich zum arithmetischen Mittel und der euklidischen Distanz (b), eine deutlich bessere Trennung beider Klassen.

Anschließend erfolgte eine Extraktion der Daten, mit einem Zeitfenster von 2 s, aus der Aufnahme. Danach wurden für beide Klassen die mittlere Kovarianzmatrix und für jede Kovarianzmatrix die Distanzen zu den mittleren Kovarianzmatrizen beider Klassen berechnet. Auf der Abszisse wurden die Distanzen zu der Klasse „geöffnete Augen“ aufgetragen und auf der Ordinate die Distanzen zu der Klasse „geschlossene Augen“. Die gestrichelte Linie stellt die Trennlinie dar, auf welcher die Distanzen zu beiden mittleren Kovarianzmatrizen identisch sind. Wie in den Diagrammen zu sehen, ermöglicht das Riemannsche Mittel und die Riemannsche Distanz (Abbildung 5.1a), im Vergleich zum arithmetischen Mittel und der euklidischen Distanz (Abbildung 5.1b), eine deutlich bessere Trennung beider Klassen.

Aufgrund der besseren Trennung beider Klassen wurde das Riemannsche Mittel und die Riemannsche Distanz zur Klassifikation verwendet. Im Folgenden wird daher zu-



nächst auf die beiden Parameter eingegangen, die die beiden anschließend beschriebenen Klassifikatoren nutzen.

### Riemannsche Distanz

Sei  $\Gamma(t)$  mit  $t \in [0, 1]$  jeder Pfad zwischen den Kovarianzmatrizen  $\Gamma(0) = \Sigma_1$  und  $\Gamma(1) = \Sigma_2$ . Der kürzeste Pfad zwischen den beiden Kovarianzmatrizen wird als Geodäte bezeichnet. Die Riemannsche Distanz zwischen den Matrizen entspricht der Länge dieser Kurve. Entsprechend der Informationsgeometrie ist die Riemannsche Distanz gegeben durch [122]:

$$\delta_R(\Sigma_1, \Sigma_2) = \|\text{Log}(\Sigma_1^{-1}\Sigma_2)\|_F = \left[ \sum_{i=1}^C \log^2 \lambda_i \right]^{1/2} \quad (5.4)$$

mit  $\lambda_i$ ,  $i = 1 \dots C$  den realen Eigenwerten von  $\Sigma_1^{-1}\Sigma_2$  und  $C$  die Anzahl an Elektroden.  $\|\cdot\|_F$  ist die Frobenius-Norm einer Matrix.

### Riemannsche Mittel

Das Riemannsche geometrische Mittel von  $I$  Kovarianzmatrizen, auch als Fréchet-Mittel bezeichnet, ist definiert als die Matrix, die die Summe der quadrierten Riemannschen Distanzen minimiert [122]:

$$\mathfrak{G}(\Sigma_1, \dots, \Sigma_I) = \arg \min_{\Sigma} \sum_{i=1}^I \delta_R^2(\Sigma, \Sigma_i). \quad (5.5)$$

Für diese Berechnung existiert keine Lösung in geschlossener Form, jedoch können iterative Algorithmen angewendet werden. Einen solchen Algorithmus stellt der Algorithmus 1 [10] dar. Dieser nutzt zur Berechnung den Tangentialraum, der eine Verwendung des arithmetischen Mittels erlaubt. Im Tangentialraum können die Kovarianzmatrizen vektorisiert und als euklidische Objekte behandelt werden. Dadurch ist es möglich, Methoden des maschinellen Lernens zu verwenden [11]. Der Klassifikator FGMDRM kann hierdurch die Fisher'sche lineare Diskriminanzanalyse zur Filterung nutzen.

Sei eine Kovarianzmatrix  $\Sigma$  gegeben, so lässt sich für jede Kovarianzmatrix  $\Sigma_i$  ein Tangentialvektor  $\Theta_i$  bestimmen. Über eine logarithmische Transformation erfolgt der

Übergang in den Tangentialraum. Eine exponentielle Transformation ermöglicht den Wechsel zurück zum ursprünglichen Raum von symmetrisch positiv-definiten (SPD)-Matrizen. Beide Transformationen sind wie folgt definiert [7]:

$$\text{Log}_{\Sigma}(\Sigma_i) = \Theta_i = \Sigma^{1/2} \text{Log} \left( \Sigma^{-1/2} \Sigma_i \Sigma^{-1/2} \right) \Sigma^{1/2}, \quad (5.6)$$

$$\text{Exp}_{\Sigma}(\Theta_i) = \Sigma_i = \Sigma^{1/2} \text{Exp} \left( \Sigma^{-1/2} \Theta_i \Sigma^{-1/2} \right) \Sigma^{1/2}. \quad (5.7)$$

Zur Berechnung des Riemannschen Mittels wird zu Beginn das arithmetische Mittel als Startwert verwendet (Zeile 1). Mit dieser Kovarianzmatrix erfolgt die Transformation des gesamten Datensatzes in den Tangentialraum. In diesem Tangentialraum findet über alle Tangentialvektoren die Berechnung des arithmetischen Mittels statt (Zeile 3). Zum Schluss wird das arithmetische Mittel in den Raum von SPD-Matrizen transformiert (Zeile 4) und dient in der nächsten Iteration als neuer Startwert. Sobald keine Änderung des Mittels mehr auftritt oder eine festgelegte Anzahl an Iterationen überschritten ist, terminiert der Algorithmus (Zeile 5 bis 6).

---

**Algorithmus 1** Berechnung des Riemannschen Mittels

---

**Eingabe:** Ein Satz von  $M$  Kovarianzmatrizen  $\Sigma = [\Sigma_1, \dots, \Sigma_M] \in \mathbb{R}^{C \times C \times M}$ .

**Eingabe:**  $\epsilon > 0$ ,  $Iter_{\max} > 0$ , Kriterien für die Terminierung.

**Ausgabe:**  $\Sigma_{\mathfrak{G}} \in \mathbb{R}^{C \times C}$ , der berechnete Riemannsche Mittelwert.

1: Initialisiere  $\Sigma_{\mathfrak{G}}^{(1)} = \frac{1}{M} \sum_{i=1}^M \Sigma_i$ ,  $iter = 0$

2: **repeat**

3:      $\Theta = \frac{1}{M} \sum_{i=1}^M \text{Log}_{\Sigma_{\mathfrak{G}}^{(t)}}(\Sigma_i)$

▷ Gleichung 5.6

4:      $\Sigma_{\mathfrak{G}}^{(t+1)} = \text{Exp}_{\Sigma_{\mathfrak{G}}^{(t)}}(\Theta)$

▷ Gleichung 5.7

5: **until** ( $\|\Theta\|_F < \epsilon$ )  $\vee$  ( $++iter > Iter_{\max}$ )

6: **return**  $\Sigma_{\mathfrak{G}}$

---

**Minimum Distance to Riemannian Mean (MDRM)-Klassifikator**

In einem ersten Schritt berechnet der MDRM-Algorithmus (Algorithmus 2 [10]) die Riemannschen Mittel für jede der  $K$  Klassen anhand von Trainingsdaten (Zeile 1 bis 3). Daraufhin wird die zu klassifizierende Kovarianzmatrix der Klasse zugeordnet, de-

ren Mittel am nächsten liegt (Zeile 4 bis 5). Die Entscheidung basiert dabei auf der Riemannschen Distanz.

---

**Algorithmus 2** MDRM-Klassifikator

---

**Eingabe:** Ein Satz von  $M$  Kovarianzmatrizen  $\Sigma = [\Sigma_1, \dots, \Sigma_M] \in \mathbb{R}^{C \times C \times M}$  für  $K$  verschiedene Klassen.

**Eingabe:**  $\mathcal{I}^{(k)}$ , die Indizes der Kovarianzmatrizen, die zu der Klasse  $k$  gehören.

**Eingabe:**  $\Sigma_x \in \mathbb{R}^{C \times C}$ , die zu klassifizierende Kovarianzmatrix.

**Ausgabe:**  $y_x$ , die ermittelte Klasse der Kovarianzmatrix  $\Sigma_x$ .

```

1: for  $k = 1$  to  $K$  do
2:    $\Sigma_{\mathfrak{G}}^{(k)} = \mathfrak{G}(\Sigma_i | i \in \mathcal{I}^{(k)})$  ▷ Gleichung 5.5
3: end for
4:  $y_x = \arg \min_k \delta_R(\Sigma_x, \Sigma_{\mathfrak{G}}^{(k)})$  ▷ Gleichung 5.4
5: return  $y_x$ 

```

---

**Filter Geodesic Minimum Distance to Riemannian Mean**

**(FGMDRM)-Klassifikator**

Der FGMDRM-Klassifikator (Algorithmus 3 [10]) ist eine Erweiterung des MDRM-Klassifikators um eine Filterung der Kovarianzmatrizen im Tangentialraum.

Die Berechnung der Filter erfolgt von Zeile 1 bis 6. Zuerst wird das Riemannsche Mittel aller Trainingsdaten berechnet, um anschließend jede Kovarianzmatrix in den Tangentialraum projizieren zu können. Im Tangentialraum erfolgt eine Konvertierung der Matrizen in Vektoren. Der Operator  $\text{vec}(\cdot)$  konvertiert die obere Dreiecksmatrix in einen Vektor der Größe  $C(C+1)/2 \times 1$ . Anschließend wird auf die Vektoren der Trainingsdaten die Fisher'sche lineare Diskriminanzanalyse [42] für ein  $K$ -Klassenproblem angewendet, um die Projektionsvektoren zu berechnen. Das Ziel des Verfahrens besteht darin, die Intergruppenvarianz  $\Sigma_B$  zu maximieren und die Intragruppenvarianz  $\Sigma_W$  zu minimieren. Die Intragruppenvarianz wird wie folgt berechnet:

$$\Sigma_W = \sum_{i=1}^K \Sigma_i \quad (5.8)$$

mit

$$\Sigma_i = \sum_{\mathbf{x} \in \mathbf{D}_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T \quad (5.9)$$

und

$$\mathbf{m}_i = \frac{1}{N_i} \sum_{\mathbf{x} \in \mathbf{D}_i} \mathbf{x}. \quad (5.10)$$

$\mathbf{D}_i$  steht für den Datensatz der Klasse  $i$  bestehend aus den  $N_i$  Vektoren  $\mathbf{x}_1, \dots, \mathbf{x}_{N_i}$  mit jeweils  $(C(C+1)/2)$  Datenpunkten. Die Intergruppenvarianz ist definiert als:

$$\Sigma_B = \sum_{i=1}^K N_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (5.11)$$

mit

$$\mathbf{m} = \frac{1}{N} \sum_{i=1}^K N_i \mathbf{m}_i \quad (5.12)$$

wobei  $N$  für die Gesamtanzahl aller Vektoren steht. Die Projektionsvektoren können über die Lösung des verallgemeinerten Eigenwertproblems  $\Sigma_W^{-1} \Sigma_B$  gefunden werden. Der Filter  $\mathbf{W}$  besteht aus den  $K - 1$  Eigenvektoren mit den größten Eigenwerten.

Die Filterung aller Kovarianzmatrizen erfolgt von Zeile 7 bis 12. Zunächst findet mit der Methode der kleinsten Quadrate eine Projektion aller Tangentialvektoren statt. Anschließend werden die gefilterten Vektoren zurück in den Raum der SPD-Matrizen transformiert. Der Operator  $\text{unvec}(\cdot)$  konvertiert einen Vektor zurück in eine Matrix.

Zum Schluss erfolgt die Klassifikation von Zeile 13 bis 17. Der Algorithmus zur Klassifikation ist identisch mit dem des MDRM-Klassifikators.

### Berechnung einer Klassifikationsbewertung

Neben der Ausgabe der Klassenzugehörigkeit wird für jede Klasse eine Bewertung (engl. Score) ausgegeben. Die Bewertung der Klasse  $i$  ist das Verhältnis der geringsten Distanz (ohne die Distanz der Klasse  $i$ ) zu der Distanz der Klasse  $i$ . Dadurch besitzt die Klasse mit der geringsten Distanz die höchste Bewertung. Dieser Wert ist immer größer oder gleich Eins. Die Bewertungen ermöglichen die Berechnung von ROC-Graphen.

---

**Algorithmus 3** FGMDRM-Klassifikator

---

**Eingabe:** Ein Satz von  $M$  Kovarianzmatrizen  $\Sigma = [\Sigma_1, \dots, \Sigma_M] \in \mathbb{R}^{C \times C \times M}$  für  $K$  verschiedene Klassen.

**Eingabe:**  $\mathcal{I}^{(k)}$ , die Indizes der Kovarianzmatrizen, die zu der Klasse  $k$  gehören.

**Eingabe:**  $\mathbf{y} \in \mathbb{R}^{M \times 1}$ , ein Vektor mit den Klassenzugehörigkeiten der Kovarianzmatrizen.

**Eingabe:**  $\Sigma_x \in \mathbb{R}^{C \times C}$ , die zu klassifizierende Kovarianzmatrix.

**Ausgabe:**  $y_x$ , die ermittelte Klasse der Kovarianzmatrix  $\Sigma_x$ .

```

1:  $\Sigma_{\mathfrak{G}} = \mathfrak{G}(\Sigma_i | i = 1, \dots, M)$  ▷ Gleichung 5.5
2: for  $i = 1$  to  $M$  do
3:    $\Theta_i = \text{vec}(\text{Log}_{\Sigma_{\mathfrak{G}}}(\Sigma_i))$  ▷ Gleichung 5.6
4: end for
5:  $\Theta_x = \text{vec}(\text{Log}_{\Sigma_{\mathfrak{G}}}(\Sigma_x))$  ▷ Gleichung 5.6
6:  $\mathbf{W} = \text{LDA}(\mathbf{y}, \Theta_i | i = 1, \dots, M)$ 
7: for  $i = 1$  to  $M$  do
8:    $\tilde{\Theta}_i = \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \Theta_i$ 
9:    $\tilde{\Sigma}_i = \text{Exp}_{\Sigma_{\mathfrak{G}}}(\text{unvec}(\tilde{\Theta}_i))$  ▷ Gleichung 5.7
10: end for
11:  $\tilde{\Theta}_x = \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \Theta_x$ 
12:  $\tilde{\Sigma}_x = \text{Exp}_{\Sigma_{\mathfrak{G}}}(\text{unvec}(\tilde{\Theta}_x))$  ▷ Gleichung 5.7
13: for  $k = 1$  to  $K$  do
14:    $\Sigma_{\mathfrak{G}}^{(k)} = \mathfrak{G}(\tilde{\Sigma}_i | i \in \mathcal{I}^{(k)})$  ▷ Gleichung 5.5
15: end for
16:  $y_x = \arg \min_k \delta_R(\tilde{\Sigma}_x, \Sigma_{\mathfrak{G}}^{(k)})$  ▷ Gleichung 5.4
17: return  $y_x$ 

```

---

Mit Hilfe der ROC-Graphen lassen sich Schwellwerte bestimmen, die eine Veränderung der Leistung des Klassifikators bewirken. Falls häufig ein Fehlalarm auftritt, kann eine Reduzierung der Fehlalarmrate erfolgen, indem eine Kontrollklasse erst eine Bewertung über einen festgelegten Schwellwert erhalten muss, um ausgewählt zu werden.

### **5.2.2. Kalibrierung**

In diesem Abschnitt wird die Kalibrierung des Alphawellen-BCIs beschrieben. Die Kalibrierung dient der Aufnahme von nutzerspezifischen Trainingsdaten für den Klassifikator. Der Klassifikator benötigt die Daten für zwei unterschiedliche Zustände des Nutzers bzw. für zwei Klassen: zum einen für den Zustand, dass die Augen geschlossen sind und zum anderen für den Zustand, dass die Augen geöffnet sind. Die Daten von 17 Probanden dienen einem Vergleich der beiden Klassifikatoren MDRM und FGMDRM und einer Evaluierung des Alphawellen-BCIs.

Zur Kalibrierung wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Über die im Rahmen dieser Arbeit entwickelte Anwendung wird der Ablauf der Kalibrierung gesteuert. Die Anwendung fordert den Probanden akustisch und visuell dazu auf, entweder seine Augen zu schließen oder zu öffnen und für eine bestimmte Zeitdauer geschlossen bzw. geöffnet zu halten. Der Operator ermöglicht die Einstellung der Anzahl an Wiederholungen und die Dauer des Öffnens und des Schließens der Augen (Stimulus-Intervall).

#### **5.2.2.1. Versuchsteilnehmer**

Insgesamt wurden Kalibrierungsdaten von 17 Probanden aufgenommen. Die Gruppe bestand aus 3 Frauen und 14 Männern. Das Alter der Probanden lag zwischen 18 und

60 Jahren, mit einem Durchschnittsalter von  $27,24 \pm 9,58$  Jahren. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

### 5.2.2.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Verwendet wurden alle 22 Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter  $5\text{ k}\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

### 5.2.2.3. Versuchsprotokoll

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte eine Stunde inklusive Erläuterung der Aufgabenstellung, Präparierung des sBCI-Helmes und dem Waschen der Haare. Für jeden Probanden wurden Daten für die beiden Klassen „geschlossene Augen“ und „geöffnete Augen“ aufgenommen. In jedem der 5 Kalibrierungsdurchläufe mussten die Probanden 10 Mal die Augen schließen und öffnen. Somit lagen nach der Kalibrierung 50 Wiederholungen pro Klasse vor.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist in der Abbildung 5.2 zu sehen. In der Pre-Run-Phase erhält der Proband für 2 s Gelegenheit, sich auf den Durchlauf einzustellen. Anschließend wird der Proband akustisch und visuell dazu aufgefordert,

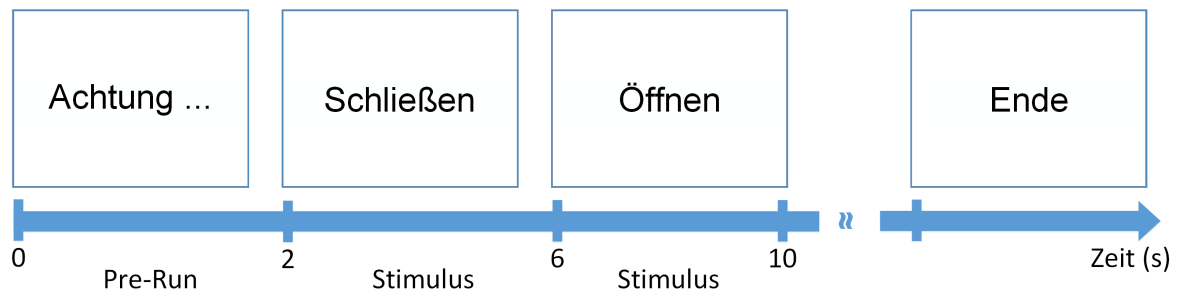


Abbildung 5.2.: Zeitlicher Ablauf der Alphawellen-Kalibrierung. Der Nutzer wird akustisch und visuell aufgefordert, entweder seine Augen zu schließen oder zu öffnen und für eine bestimmte Zeitdauer geschlossen bzw. geöffnet zu halten.

entweder seine Augen zu schließen oder zu öffnen. Innerhalb der 4 s langen Stimulus-Phase soll der Proband seine Augen geschlossen oder geöffnet halten. Der Wechsel der beiden Klassen findet solange statt, bis von jeder Klasse 10 Wiederholungen vorhanden sind.

#### 5.2.2.4. Evaluierung

Die Evaluierung der aufgenommenen Daten erfolgte, für jeden Probanden einzeln, in Matlab mit einer  $10 \times 10$ -fachen stratifizierten Kreuzvalidierung. Hierzu wurden die Daten der beiden Klassen „geschlossene Augen“ und „geöffnete Augen“ aus den Kalibrierungsaufnahmen extrahiert. Die Extraktion der Daten erfolgte alle 500 ms mit einem Zeitfenster von 2 s. Da die Probanden nicht sofort ihre Augen geschlossen oder geöffnet hatten, wurden nur Signale in einem Intervall von 1 bis 4 s nach dem Stimulus berücksichtigt. Der Algorithmus aus Abschnitt 5.2.1 diente der Verarbeitung der Signale. Aufgrund der ausreichenden Anzahl an Datenpunkten wurden die Kovarianzmatrizen empirisch geschätzt. Für jeden Probanden und jeden der beiden Klassifikatoren MDRM und FGMDRM wurden die Klassifikationsgenauigkeit (ACC), die Sensitivität (TPR), die Spezifität (TNR) und die Fläche unterhalb der ROC-Kurve (AUC) bestimmt. Die



Klasse „geschlossene Augen“ dient dem Stoppen des Roboterarmes und ist daher die positive Klasse.

In der Abbildung 5.3 sind die Zeit-Frequenz-Diagramme eines Probanden zu sehen, der zum Zeitpunkt 0 s seine Augen schließt und diese für die nachfolgenden 2 s geschlossen hält. Den Diagrammen liegen 50 Wiederholungen zugrunde. Zwischen 0 und 0,5 s ist ein deutlicher Leistungsanstieg im Frequenzbereich unterhalb von 8 Hz zu sehen. Dieser Anstieg entsteht aufgrund des Artefaktes beim Schließen der Augen. Bereits nach 0,5 s ist ein Anstieg der Leistung im Alphafrequenzbereich (8 bis 12 Hz) feststellbar. Am stärksten treten Alphawellen im okzipitalen Bereich des Gehirns auf (Kanal  $O_z$ ). Die Elektroden über dem frontalen (Kanal  $FC_z$ ) und zentralen (Kanal  $C_z$ ) Bereich des Gehirns messen ebenfalls einen starken Leistungsanstieg im Alphafrequenzbereich. Über dem zentralen-parietalen und parietalen Bereich (Kanal  $CP_z$  und  $P_z$ ) ist nur ein geringer Anstieg der Leistung zu beobachten.

Die Abbildung 5.4 zeigt die Verteilungen der Klassifikationsergebnisse über alle Probanden. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle C.1. Wie in dem Diagramm zu sehen, liefert der Klassifikator FGMDRM deutlich bessere Ergebnisse als der Klassifikator MDRM. Die mittlere Genauigkeit von MDRM liegt bei  $96,68 \% \pm 3,89 \%$  und von FGMDRM bei  $99,38 \% \pm 0,94 \%$ . Beim MDRM-Klassifikator liegen 75 % der Genauigkeiten über 94,40 % und beim FGMDRM-Klassifikator über 98,98 %. Außerdem ist die minimale Genauigkeit von FGMDRM mit 97,53 % deutlich höher als die von MDRM mit 90,87 %. Bei den anderen Parametern verhält es sich ähnlich, wobei die Spezifität immer größer ist als die Sensitivität. In der Arbeit [78] liegt die mittlere Genauigkeit von 3 Probanden bei  $80,13 \pm 19,97 \%$ , die minimale Genauigkeit bei 45 %, die maximale Genauigkeit bei 98 % und 75 % der Werte liegen über 74 %. Diese Arbeit nutzte eine FFT zur Detektion von Alphawellen.

Anhand der Ergebnisse dieser Kalibrierung wurde gezeigt, dass Alphawellen bei allen Probanden auftreten und zuverlässig detektiert werden können. Die zusätzliche Filterung des FGMDRM-Algorithmus bewirkt eine deutliche Verbesserung der Klassifika-

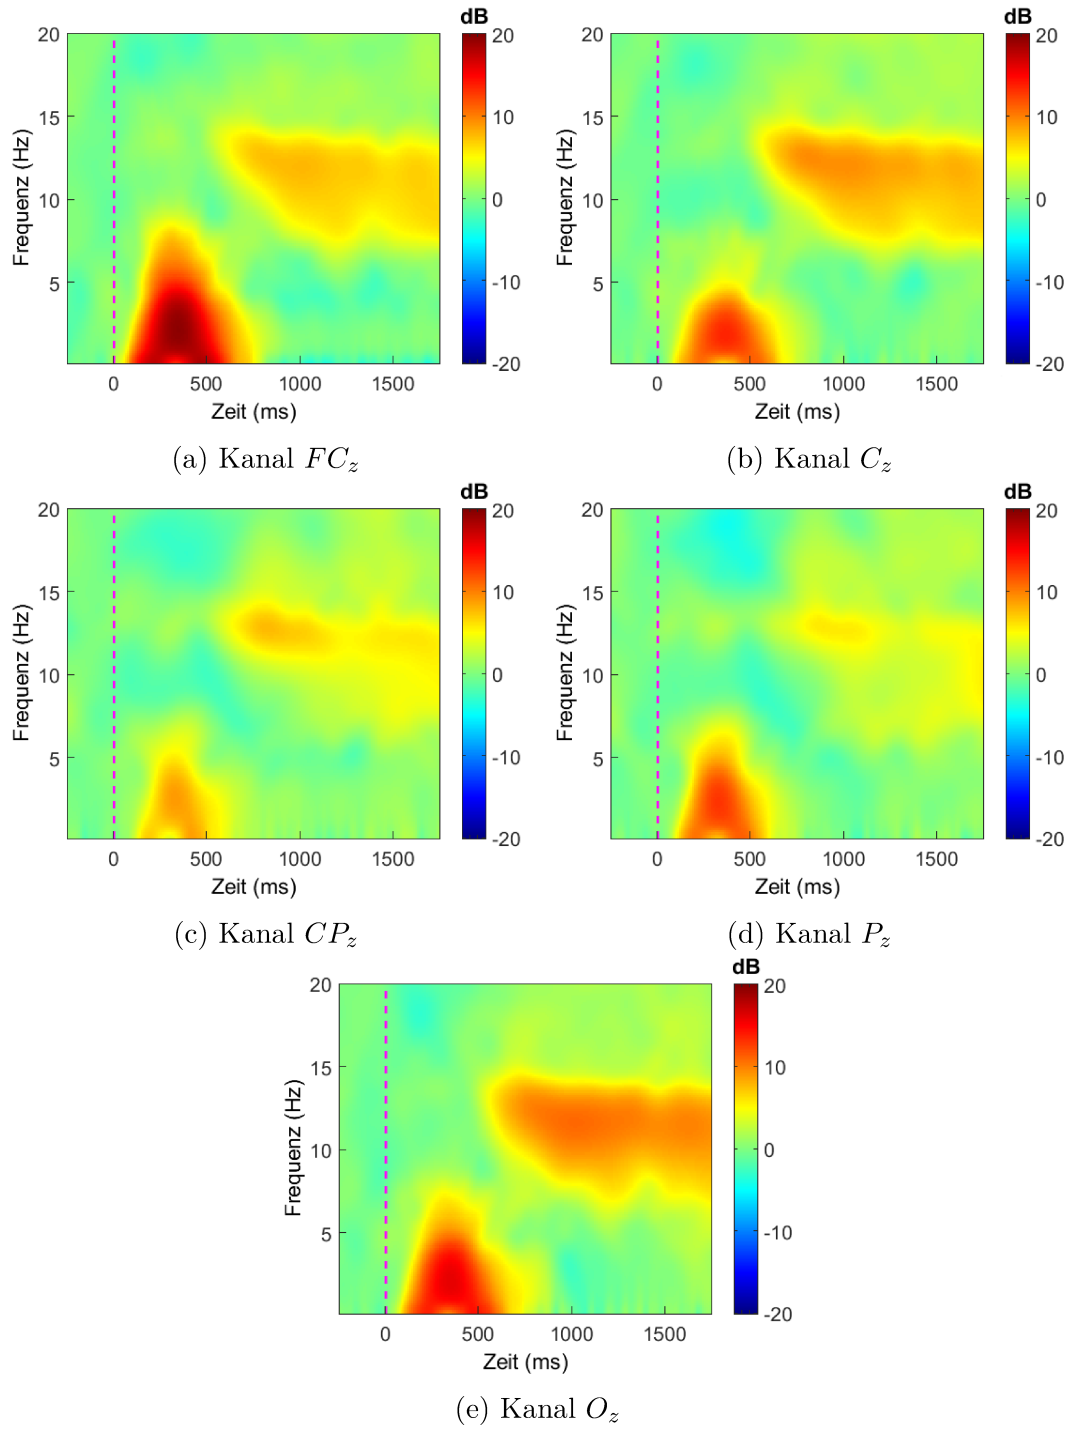


Abbildung 5.3.: Zeit-Frequenz-Diagramme eines Probanden, der zum Zeitpunkt 0 s die Instruktion erhielt, seine Augen zu schließen und für 2 s geschlossen zu halten. Nach ca. 500 ms tritt eine erhöhte Aktivität im Alphafrequenzbereich auf.

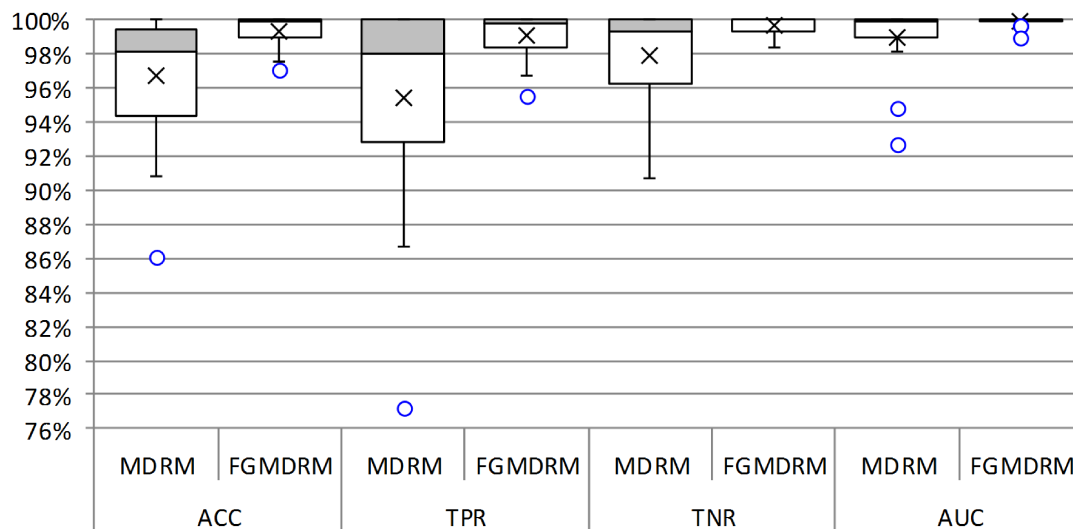


Abbildung 5.4.: Ergebnisse für die Klassifikation von geschlossenen (positive Klasse) und geöffneten (negative Klasse) Augen anhand von Alphawellen. Den Verteilungen liegen die Ergebnisse aller Probanden zugrunde.

tionsergebnisse. Im Gegensatz zu der Verwendung einer FFT, liefert der FGMDRM-Algorithmus für alle Probanden eine sehr hohe Genauigkeit. Daher wurde bei der Vergleichsstudie der Stoppmodalitäten (Abschnitt 5.4) und dem Test der geschwindigkeitsbasierten Roboterarmsteuerung (Abschnitt 5.5) dieser Klassifikator für das Alphawellen-BCI verwendet. Da alle aufgenommenen Kanäle für die Klassifikation nützliche Informationen enthalten, wurden bei den Studien alle Elektroden des sBCI-Helmes für das Alphawellen-BCI verwendet.

### 5.3. Augenartefakte als Stoppmodalität

Im vorherigen Abschnitt wurde gezeigt, dass ein Geschlossen- und Geöffnethalten der Augen anhand von Alphawellen detektiert werden kann. Weiterhin wurde gezeigt, dass, während des Schließens und Öffnens der Augen, im EEG Artefakte auftreten, die die Gehirnsignale überlagern. Der Mensch ist in der Lage, diese Artefakte willentlich und schneller als Alphawellen zu erzeugen. Dieser Abschnitt beschreibt das asynchrone HMI zur Detektion von Augenartefakten, das zum Stoppen des Roboterarmes verwendet wird.

Das System ist in der Lage, Augenartefakte, die beim Öffnen und Schließen der Augen und beim Blinzeln entstehen, zu detektieren und vom artefaktfreien Ruhezustand zu unterscheiden. Sobald die Signalverarbeitung das Augenartefakt beim Schließen der Augen detektiert, wird ein Kommando an den Roboter gesendet, das diesen zum Stoppen bringt. Der Nutzer kann somit über ein Schließen der Augen den Greifer an der Zielposition und in Gefahrensituationen zum Stoppen bringen. Die anderen Artefakte dienen lediglich einer Verbesserung der Robustheit des Systems.

Zu Beginn dieses Abschnittes erfolgt eine Beschreibung der Signalverarbeitung, die Augenartefakte und den Ruhezustand detektiert. Zum Schluss wird die Kalibrierung beschrieben, die Daten für den zu trainierenden Klassifikator aufnimmt. Kalibrierungsergebnisse von 14 Probanden dienen der Evaluierung des Augenartefakt-HMIs.

### **5.3.1. Signalverarbeitung**

Die Signalverarbeitung, zur Detektion des Ruhezustandes und der Augenartefakte beim Öffnen, Schließen und Blinzeln der Augen, nutzt die beiden Klassifikatoren MDRM und FGMDRM. Beide Algorithmen nutzen Kovarianzmatrizen als Merkmale und die Riemannsche Geometrie zur Verarbeitung der Matrizen. Sie benötigen für jede Klasse einen Satz an Trainingsdaten mit bekannter Klassenzugehörigkeit, die im Rahmen einer Kalibrierung aufgenommen wurden. Eine Beschreibung der beiden Klassifikatoren ist dem Abschnitt 5.2.1.2 zu entnehmen. Vor der Klassifikation erfolgt eine räumliche Filterung der Signale, um die Anzahl an Dimensionen zu reduzieren und das Signal-Rausch-Verhältnis zu verbessern. Um die zeitliche Information der Signale zu berücksichtigen, wird eine besondere Schätzung der Kovarianzmatrix verwendet. Zur Detektion von Augenartefakten wurden die Algorithmen noch nicht verwendet.

Alternativ lassen sich Artefakte durch die Extraktion von Merkmalen mit einem AR-Modell und durch die Verwendung einer SVM klassifizieren. Diese Art der Klassifikation benötigt mehrere zu bestimmende Parameter. Zu diesen Parametern gehört die Ordnung

des AR-Modells sowie zwei Parameter für die SVM [100]. Ein Vergleich der Leistung der Algorithmen ist dem Abschnitt 5.3.2 zu entnehmen.

#### 5.3.1.1. Signalvorverarbeitung

Augenartefakte liegen in einem sehr niedrigen Frequenzbereich. Im Rahmen der Vorverarbeitung werden zuerst die Signale einer Bandpassfilterung zwischen 0,1 und 15 Hz unterzogen. Dabei wird ein Butterworth-Bandpassfilter fünfter Ordnung eingesetzt.

Um das Signal-Rausch-Verhältnis zu verbessern und die Anzahl an Dimensionen zu reduzieren, erfolgt anschließend eine räumliche Filterung der Signale. Für jede der insgesamt  $K$  Klassen werden  $N_{\text{Filter}}$  räumliche Filter erstellt. Im Falle der Detektion des Ruhezustandes und der Augenartefakte beim Öffnen, Schließen und Blinzeln der Augen, ist  $K = 4$ . Die räumliche Filterung ist eine Anpassung der CSP-Methode an Signale, deren hauptsächlichster Informationsgehalt im Zeitbereich liegt [25]. Für die Berechnung der Filter werden die gemittelten Datensegmente der Klassen benötigt. Sei  $\mathbf{X}_i \in \mathbb{R}^{C \times N}$  das  $i$ -te Datensegment, mit  $C$  der Anzahl an Kanälen und  $N$  der Anzahl an Datenpunkten. Das gemittelte Datensegment der Klasse  $k$  ist definiert als [25]:

$$\mathbf{P}^{(k)} = \frac{1}{|\mathcal{I}^{(k)}|} \sum_{i \in \mathcal{I}^{(k)}} \mathbf{X}_i \quad (5.13)$$

mit  $\mathcal{I}^{(k)}$  den Indizes der Datensegmente, die zu der Klasse  $k$  gehören. Der räumliche Filter  $\mathbf{w} \in \mathbb{R}^{C \times 1}$  löst das folgende Optimierungsproblem der Klasse  $k$  [25]:

$$\mathbf{w}^* = \arg \max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{P}^{(k)} \mathbf{P}^{(k)T} \mathbf{w}}{\mathbf{w}^T \mathbf{X} \mathbf{X}^T \mathbf{w}} \quad (5.14)$$

wobei  $\mathbf{X}$  die Matrix ist, die die kontinuierliche EEG-Aufnahme enthält. Hier wird die Matrix durch Konkatenation der Datensegmente aller Klassen gebildet. Bei der Gleichung handelt es sich um den Rayleigh-Quotienten, dessen Maxima durch die Lösung

des verallgemeinerten Eigenwertproblems  $(\mathbf{X}\mathbf{X}^T)^{-1}(\mathbf{P}^{(k)}\mathbf{P}^{(k)T})$  gefunden werden können. Die  $N_{\text{Filter}}$  Eigenvektoren mit den höchsten Eigenwerten bilden die räumlichen Filter  $\mathbf{W}^{(k)} \in \mathbb{R}^{C \times N_{\text{Filter}}}$  der Klasse  $k$ . Diese Filter erzeugen die Kanäle mit dem größten Signal-Rausch-Abstand.

Die räumliche Filterung erfolgt durch die lineare Projektion des Datensegmentes  $i$  mit der Matrix  $\mathbf{W} = [\mathbf{W}^{(1)}, \dots, \mathbf{W}^{(K)}] \in \mathbb{R}^{C \times (K \cdot N_{\text{Filter}})}$  [25]:

$$\mathbf{Z}_i = \mathbf{W}^T \mathbf{X}_i. \quad (5.15)$$

Bei der Matrix  $\mathbf{W}$  handelt es sich um die Aggregation der räumlichen Filter aller  $K$  Klassen in einer einzigen Matrix.

Die gewöhnliche Kovarianzmatrix enthält zwar die räumliche, nicht jedoch die zeitliche Information eines Datensegmentes. Daher wird eine besondere Schätzung der Kovarianzmatrix verwendet. Hierfür wird ein neues Datensegment  $\tilde{\mathbf{Z}}_i \in \mathbb{R}^{(2 \cdot K \cdot N_{\text{Filter}}) \times N}$  gebildet, das aus den räumlich gefilterten Mittelwerten aller Klassen und dem räumlich gefilterten Datensegment  $\mathbf{Z}_i$  besteht [25]:

$$\tilde{\mathbf{Z}}_i = [\mathbf{W}^{(1)T} \mathbf{P}^{(1)}, \dots, \mathbf{W}^{(K)T} \mathbf{P}^{(K)}, \mathbf{Z}_i]^T. \quad (5.16)$$

### 5.3.1.2. Merkmalsextraktion und Klassifikation

Die Datensätze der Vorverarbeitung dienen der Erstellung von Kovarianzmatrizen. Wie bereits bei der Merkmalsextraktion vom Alphawellen-BCI (Abschnitt 5.2.1.1), werden die Kovarianzmatrizen empirisch geschätzt (Gleichung 5.1). Liegen nicht genügend Datenpunkte vor, findet eine Regularisierung der Kovarianzmatrizen statt (Gleichung 5.2).

Mit Hilfe der Kovarianzmatrizen erfolgt das Training der bereits in Abschnitt 5.2.1.2 beschriebenen Klassifikatoren MDRM und FGMDRM. Nach dem Training sind diese in der Lage, jede Kovarianzmatrix mit unbekannter Klassenzugehörigkeit zu klassifizieren.

### 5.3.2. Kalibrierung

In diesem Abschnitt wird die Kalibrierung des Augenartefakt-HMIs beschrieben. Die Kalibrierung dient der Aufnahme von nutzerspezifischen Daten für die Erstellung der räumlichen Filter und dem Training des Klassifikators. Benötigt werden die Daten von den Augenartefakten, die beim Schließen, Öffnen und Blinzeln der Augen entstehen sowie die Daten vom Ruhezustand. Insgesamt sind somit die Daten für vier Klassen notwendig. Die Daten von 14 Probanden dienen einem Vergleich der beiden Klassifikatoren MDRM und FGMDRM und einer Evaluierung des Augenartefakt-HMIs.

Zur Kalibrierung wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Über die im Rahmen dieser Arbeit entwickelte Anwendung wird der Ablauf der Kalibrierung gesteuert. In einem Modus fordert die Anwendung den Probanden akustisch und visuell dazu auf, entweder seine Augen zu schließen oder zu öffnen und für eine bestimmte Zeitdauer geschlossen bzw. geöffnet zu halten. In einem weiteren Modus wird der Nutzer aufgefordert, zu einem bestimmten Zeitpunkt zu blinzeln oder für ein bestimmtes Zeitintervall kein Artefakt zu erzeugen. Der Operator ermöglicht die Einstellung der Anzahl an Wiederholungen und des Zeitintervalls zwischen zwei Artefakten (Stimulus-Intervall).

#### 5.3.2.1. Versuchsteilnehmer

Insgesamt wurden Kalibrierungsdaten von 14 Probanden aufgenommen. Die Gruppe bestand aus 3 Frauen und 11 Männern. Das Alter der Probanden lag zwischen 18 und 60 Jahren, mit einem Durchschnittsalter von  $27,86 \pm 10,18$  Jahren. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teil-

nehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### **5.3.2.2. Datenaufnahme**

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente der Aufnahme von EEG-Signalen. Verwendet wurden alle 22 Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

#### **5.3.2.3. Versuchsprotokoll**

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte eine Stunde inklusive Erläuterung der Aufgabenstellung, Präparierung des sBCI-Helmes und dem Waschen der Haare. Für jeden Probanden wurden Daten für die vier Klassen „Augen schließen“, „Augen öffnen“, „Blinzeln“ und „Ruhezustand“ aufgenommen. In jedem der 5 Kalibrierungsdurchläufe des ersten Modus mussten die Probanden 10 Mal die Augen schließen und öffnen. Im zweiten Modus mussten die Probanden, in jedem der 5 Durchläufe, 10 Mal mit den Augen blinzeln und die Erzeugung von Artefakten vermeiden. Somit lagen nach der Kalibrierung 50 Wiederholungen pro Klasse vor.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs des ersten Modus ist identisch zu der Alphawellen-Kalibrierung aus Abschnitt 5.2.2. In der Abbildung 5.5 ist der zeitliche Ablauf eines Kalibrierungsdurchlaufs des zweiten Modus zu sehen. In der Pre-Run-Phase erhält der Proband für 2 s Gelegenheit, sich auf den Durchlauf einzustellen. Anschließend



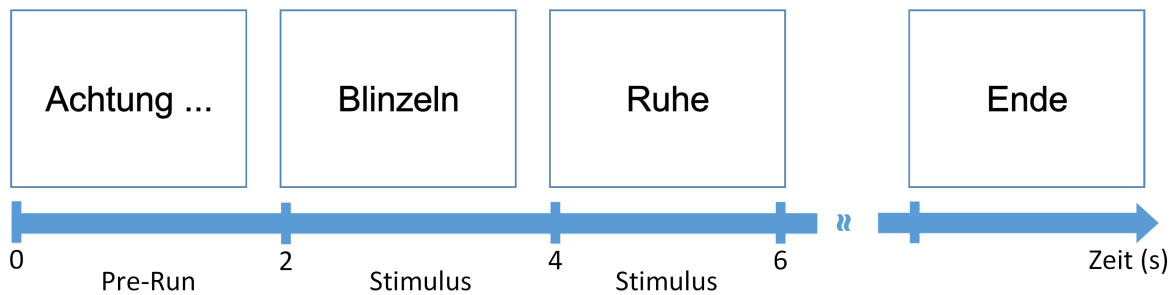


Abbildung 5.5.: Zeitlicher Ablauf der Augenartefakt-Kalibrierung. Der Nutzer wird akustisch und visuell aufgefordert, entweder mit den Augen zu blinzeln oder die Erzeugung von Artefakten zu vermeiden.

wird der Proband akustisch und visuell dazu aufgefordert, entweder mit den Augen zu blinzeln oder die Erzeugung von Artefakten zu vermeiden. Der Wechsel der beiden Klassen findet alle 2 s statt und erfolgt solange, bis von jeder Klasse 10 Wiederholungen vorhanden sind.

#### 5.3.2.4. Evaluierung

Die Evaluierung der aufgenommenen Daten erfolgte, für jeden Probanden einzeln, in Matlab mit einer  $10 \times 10$ -fachen stratifizierten Kreuzvalidierung. Hierzu wurden die Daten der vier Klassen „Augen schließen“, „Augen öffnen“, „Blinzeln“ und „Ruhezustand“ aus den Kalibrierungsaufnahmen extrahiert. Die Extraktion der Daten erfolgte mit einem Zeitfenster von 2 s. Jedes Datensegment beginnt 0,25 s vor und endet 1,75 s nach dem Stimulus. Der Algorithmus aus Abschnitt 5.3.1 diente der Verarbeitung der Signale. Für jede Klasse wurde ein räumlicher Filter berechnet. Aufgrund der ausreichenden Anzahl an Datenpunkten wurden die Kovarianzmatrizen empirisch geschätzt. Für jeden Probanden und jeden der beiden Klassifikatoren MDRM und FGMDRM wurden die Klassifikationsgenauigkeit (ACC), die Sensitivität (TPR), die Spezifität (TNR) und die Fläche unterhalb der ROC-Kurve (AUC) bestimmt. Die Klasse „Augen schließen“ dient dem Stoppen des Roboterarmes und ist daher die positive Klasse. Alle anderen Klassen bilden zusammen die negative Klasse.

In der Abbildung 5.6 sind die zeitlichen und topografischen Diagramme eines Probanden zu sehen, der zum Zeitpunkt 0 s die Instruktion erhielt, seine Augen zu schließen oder zu öffnen, mit den Augen zu blinzeln oder keine Artefakte zu erzeugen. Den Diagrammen liegen 50 Wiederholungen zugrunde. Zwischen 380 und 800 ms nach dem Stimulus erreichen die Signale der Augenartefakte ihre Extremwerte. Die maximale Amplitude beträgt  $64,2 \mu\text{V}$ . Die Amplitude fällt nach einem Blinzeln deutlich eher ab und ist außerdem geringer als nach einem Schließen der Augen. Am stärksten treten Augenartefakte im frontalen Bereich des Gehirns auf (Kanal  $FC_z$ ), da dieser den Augen und somit der Quelle der Artefakte am nächsten liegt. Im okzipitalen Bereich des Gehirns (Kanal  $O_z$ ) sind dieselben Signalverläufe zu sehen, allerdings in invertierter Form. Mit zunehmender Distanz von den Elektroden  $FC_z$  und  $O_z$  nehmen die Amplituden der Signale ab.

Die Abbildung 5.7 zeigt die Verteilungen der Klassifikationsergebnisse über alle Probanden. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle C.2. Wie in dem Diagramm zu sehen, liefert der Klassifikator FGMDRM nur geringfügig bessere Ergebnisse als der Klassifikator MDRM. Die mittlere Genauigkeit von MDRM liegt bei  $98,72 \pm 1,20 \%$  und von FGMDRM bei  $99,04 \pm 1,00 \%$ . Beim MDRM-Klassifikator liegen 75 % der Genauigkeiten über 97,92 % und beim FGMDRM-Klassifikator über 98,47 %. Die minimale Genauigkeit von FGMDRM liegt bei 96,40 % und die von MDRM bei 96,20 %. Bei den anderen Parametern verhält es sich ähnlich, wobei die Spezifität immer größer ist als die Sensitivität. In der Arbeit [100] wurde zwar kein Schließen der Augen betrachtet, jedoch Artefakte, die beim Blinzeln und bei den Bewegungen der Augen entstehen. Die mittlere Genauigkeit von 7 Probanden, zur Detektion eines Blinzelns, liegt bei  $98,00 \pm 4,79 \%$ , die minimale Genauigkeit bei 93,00 % und 75 % der Werte liegen über 96,75 %. Diese Arbeit nutzte ein AR-Modell und eine SVM zur Detektion von Artefakten.

Anhand der Ergebnisse dieser Kalibrierung wurde gezeigt, dass Augenartefakte bei allen Probanden auftreten und zuverlässig detektiert werden können. Verglichen mit anderen Algorithmen aus der Literatur, besitzen die Algorithmen dieser Arbeit eine

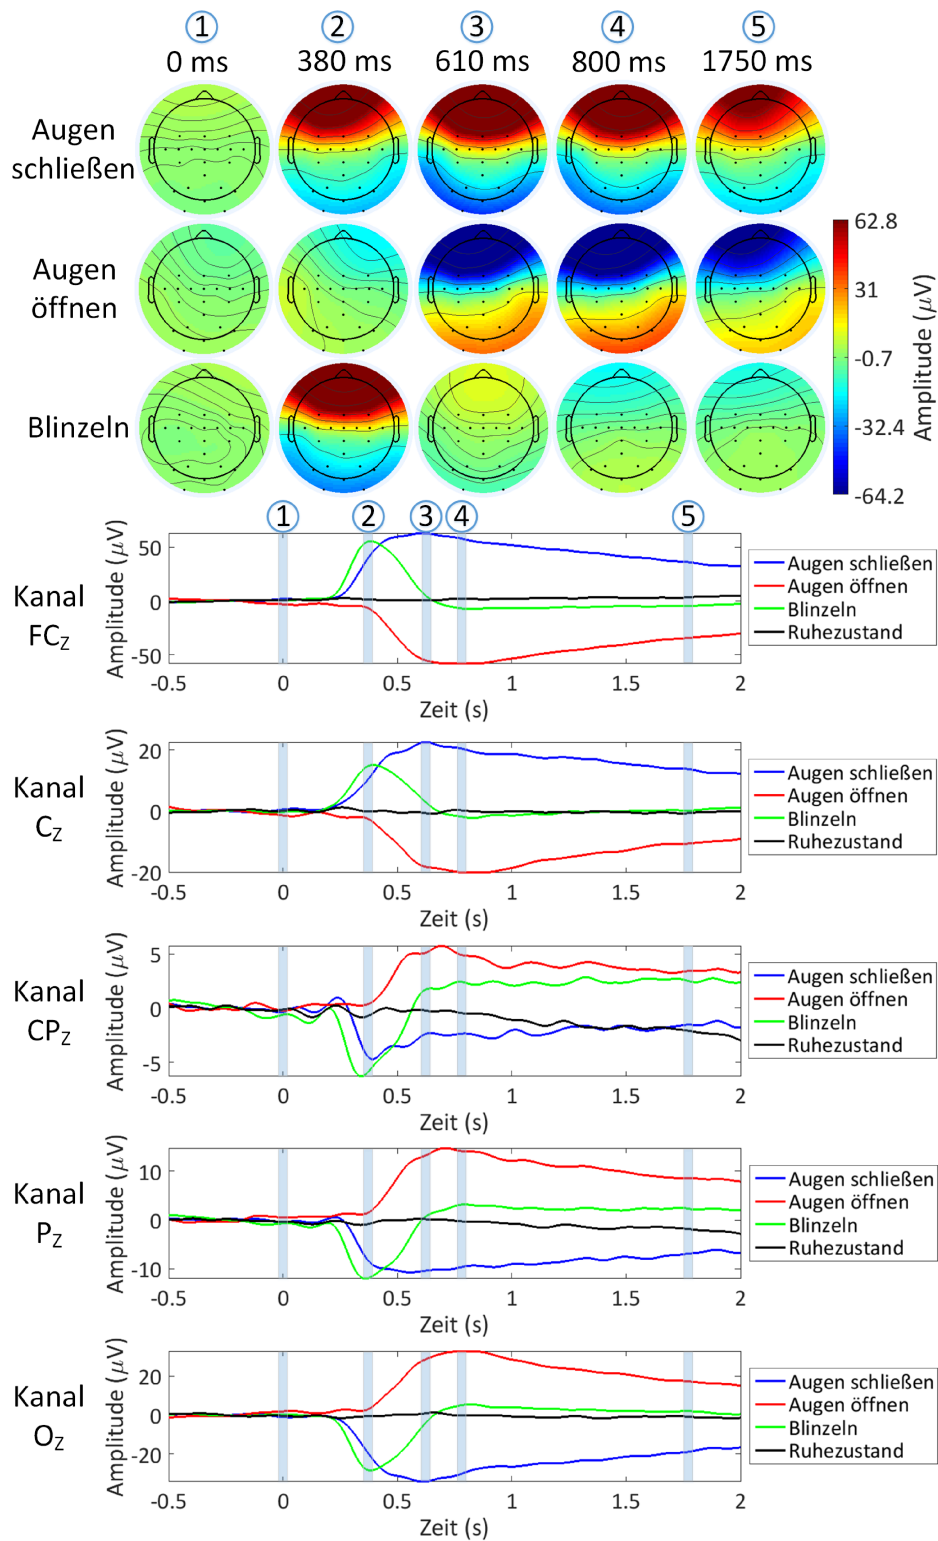


Abbildung 5.6.: Zeitliche und topografische Darstellung von Augenartefakten.




Abbildung 5.7.: Ergebnisse für die Klassifikation von einem Schließen der Augen (positive Klasse) sowie einem Öffnen der Augen, einem Blinzeln und dem Ruhezustand (negative Klassen) anhand von Augenartefakten. Den Verteilungen liegen die Ergebnisse aller Probanden zugrunde.

etwas höhere Genauigkeit. Die zusätzliche Filterung des FGMDRM-Algorithmus bewirkt nur eine geringfügige Verbesserung der Klassifikationsergebnisse. Trotzdem wurde bei der Vergleichsstudie der Stopppmodalitäten (Abschnitt 5.4) und dem Test der geschwindigkeitsbasierten Roboterarmsteuerung (Abschnitt 5.5) dieser Klassifikator für das Augenartefakt-HMI verwendet. Da alle aufgenommenen Kanäle für die Klassifikation nützliche Informationen enthalten, wurden bei den Studien alle Elektroden des sBCI-Helmes für das Augenartefakt-HMI verwendet.

## 5.4. Vergleich der Stopppmodalitäten

Im Rahmen dieser Studie wurden die Stopppmodalitäten verglichen. Eine Übersicht über das dabei verwendete System befindet sich im Abschnitt 5.1. Anstelle des Zustandsautomaten wurde eine mit dem BCI2000-Framework [156] implementierte Testanwendung benutzt. Der Roboter empfing während des Experiments keine Kommandos und blieb ausgeschaltet. Die Probanden nutzten das Alphawellen-BCI aus Abschnitt 5.2, das




Abbildung 5.8.: Zeitlicher Ablauf für den Test einer Stoppmodalität. Während der Pre-Feedback-Phase wird dem Probanden das Ziel angezeigt. Anschließend folgt die Feedback-Phase, in der sich ein Cursor horizontal vom linken bis zum rechten Bildschirmrand bewegt. Durch ein Kommando muss der Proband den Cursor mittig über dem Ziel zum Stoppen bringen. Zum Schluss wird dem Probanden in der Post-Feedback-Phase angezeigt, an welcher Position der Cursor gestoppt hat.

Augenartefakt-HMI aus Abschnitt 5.3 und das frequenzbasierte SSVEP-BCI aus Abschnitt 4.2 für ein aktives Stoppen in einer Testanwendung. Bei einem aktiven Stoppen sendet der Nutzer bewusst und aus eigener Initiative ein Kommando aus. Im Falle der drei genannten Modalitäten geschieht dies durch ein Geschlossenhalten der Augen, ein Schließen der Augen bzw. durch die Aufmerksamkeitsverschiebung auf eine LED. Für ein passives Stoppen nutzten die Probanden das ERP-BCI aus Abschnitt 6.2. Bei einem passiven Stoppen nimmt der Nutzer die Rolle eines Beobachters ein und sendet unbewusst und nicht aus eigener Initiative ein Kommando aus. Im Falle der genannten Modalität treten ereigniskorrelierte Potenziale auf, sobald die Zielposition erreicht ist und der Nutzer dieses Ereignis registriert. Über die Detektion dieser Potenziale wird dann ein Stoppen ausgelöst. Die Stimulation für das frequenzbasierte SSVEP-BCI erfolgte über die LEDs des in Abschnitt 3.1 beschriebenen sBCI-Helmes. Innerhalb der Testanwendung bewegt sich ein Cursor vom linken bis zum rechten Bildschirmrand. Die Probanden erhielten die Aufgabe, in mehreren Versuchen, den Cursor über einem definierten Ziel zum Stoppen zu bringen. Insgesamt wurden die Tests mit fünf verschiedenen Geschwindigkeiten des Cursors durchgeführt. Der zeitliche Ablauf eines einzelnen Versuchs ist in der Abbildung 5.8 zu sehen.

Tabelle 5.1.: Informationen über die Probanden, die an der Studie zum Vergleich der Stoppmodalitäten teilnahmen.

Paradigma	Geschlecht		Alter			
	weibl.	männl.	Min.	Max.	Mittelw.	SD
Alphawellen	3	8	18	60	28,45	11,30
Augenartefakte	3	7	23	60	29,75	12,77
SSVEP (Frequenz)	3	7	18	33	26,20	4,71
ERP	1	7	18	60	29,80	12,49

Anhand der ermittelten Zuverlässigkeiten, Genauigkeiten und Detektionszeiten wurden die geeignetsten Modalitäten und Geschwindigkeiten ausgewählt und in dem in Abschnitt 5.5 beschriebenen Test der geschwindigkeitsbasierten Roboterarmsteuerung verwendet.

#### 5.4.1. Versuchsteilnehmer

An jedem der vier Experimente nahmen 8 bis 11 Probanden teil. Aufgrund eines hohen zeitlichen Abstandes zwischen den Experimenten, waren die Konstellationen der Versuchsteilnehmer stets unterschiedlich. Die Informationen über die Versuchsteilnehmer, hinsichtlich Geschlechts und Alters, sind der Tabelle 5.1 zu entnehmen. Eine Probandin ist an MS erkrankt und vom Hals an abwärts gelähmt. Aufgrund einer starken Beeinträchtigung der Sehfähigkeit konnte sie nicht das SSVEP-BCI nutzen. Die anderen Paradigmen konnte sie verwenden, da diese keine visuelle Stimulation benötigen. Alle anderen Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Versuche fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen

Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

### 5.4.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Das SSVEP-BCI nutzte 8 Elektroden ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex. Die anderen Paradigmen nutzten alle Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

### 5.4.3. Versuchsprotokoll

Vor dem Versuch mussten die Probanden eine Kalibrierung durchführen. Eine Beschreibung der verwendeten Kalibrierung für das SSVEP-BCI befindet sich in Abschnitt 4.2.3, für das Alphawellen-BCI in Abschnitt 5.2.2, für das Augenartefakt-HMI in Abschnitt 5.3.2 und für das ERP-BCI in Abschnitt 6.2.2.

Beim frequenzbasierten SSVEP-BCI wurden im Rahmen der Kalibrierung die vier optimalen Stimulationsfrequenzen bestimmt. Das SSVEP-BCI nutzte die MCC-Methode zur räumlichen Filterung und Schwellwerte für die Klassifikation, die für jeden Nutzer empirisch ermittelt wurden. Neben den Stimulationsfrequenzen wurden noch weitere Frequenzen betrachtet, um die Stabilität des Systems zu verbessern. Diese lagen mit einer Abweichung von 0,5 Hz um die Stimulationsfrequenzen. Betrachtet wurden die ersten beiden Harmonischen.

Die anderen Paradigmen benötigten nutzerspezifische Kalibrierungsdaten für die Erstellung der räumlichen Filter und das Training des FGMDRM-Klassifikators. Beim

Alphawellen-BCI wurden die Trainingsdaten zwischen der ersten und vierten Sekunde nach dem Stimulus verwendet. Die Datensegmente besaßen eine Überlappung von 0,5 s und hatten bei allen Paradigmen eine Länge von 2 s. Beim Augenartefakt-HMI lag das Startfenster der Trainingsdaten bei -0,5 s vor dem Stimulus und bei dem ERP-BCI bei -0,5 s vor der Zielposition. Das Augenartefakt-HMI und das ERP-BCI nutzten für jede Klasse einen bzw. vier räumliche Filter. Aufgrund der ausreichenden Anzahl an Datenpunkten wurden die Kovarianzmatrizen empirisch geschätzt. Das Augenartefakt-HMI nutzte einen empirisch ermittelten Schwellwert innerhalb der Klassifikation. Dies war erforderlich, da ansonsten ein zu starkes Blinzeln mit einem Schließen der Augen verwechselt würde und somit ein fehlerhaftes Stopp-Kommando die Folge wäre.

Nach der Kalibrierung mussten die Probanden einen Cursor innerhalb einer Testanwendung zum Stoppen bringen. Das Stoppen erfolgte beim SSVEP-BCI über die Konzentration auf eine der vier LEDs des sBCI-Helmes. Beim Augenartefakt-HMI und beim Alphawellen-BCI stoppte der Cursor über das Schließen bzw. Geschlossenhalten der Augen. Über die Detektion von ereigniskorrelierten Potenzialen sollte der Cursor auf passive Weise zum Stoppen gebracht werden, sobald der Cursor über dem Ziel war. Die Probanden mussten in diesem Fall nicht explizit ein Kommando senden.

Insgesamt absolvierten die Probanden fünf Durchläufe für jede Stoppmodalität. Jeder Durchlauf bestand aus 20 Wiederholungen. In jedem Durchlauf behielt der Cursor eine festgelegte Geschwindigkeit bei. Getestet wurden die Geschwindigkeiten 3,5, 7, 14, 28 und 56 mm/s. Das Ziel konnte vier unterschiedliche Positionen einnehmen, die sich hinsichtlich des Abstandes zum rechten Bildschirmrand unterschieden. Jede Position wurde in einem Durchlauf 5 Mal eingenommen. Der Cursor besaß einen Durchmesser von 1,7 cm, das Ziel eine Breite von 3,4 cm und der Monitor eine Breite von 33,75 cm.

Der zeitliche Ablauf eines Durchlaufs wurde bereits in der Abbildung 5.8 gezeigt. Die Testanwendung startet mit der Pre-Run-Phase, in der der Proband für 2 s Gelegenheit erhält, sich auf den Durchlauf einzustellen. Anschließend wird in der Pre-Feedback-Phase



kurz das Ziel angezeigt. Innerhalb der Feedback-Phase bewegt sich der Cursor vom linken bis zum rechten Bildschirmrand. Das Ziel besteht darin, den Cursor mittig über dem Ziel zum Stoppen zu bringen. Sobald der Cursor stoppt oder den rechten Bildschirmrand erreicht hat, beginnt die Post-Feedback-Phase. Hier kann der Proband sehen, an welcher Stelle der Cursor gestoppt hat. Ein Stoppen des Cursors wird dem Probanden akustisch und visuell mitgeteilt. Dieser Ablauf wird mehrfach hintereinander wiederholt, damit sich der Proband mit der Zeit verbessern kann.

### 5.4.4. Evaluierung

Der Vergleich der Stoppmodalitäten erfolgt über die Kriterien Detektionszeit, Zuverlässigkeit und Genauigkeit. Auf diese Kriterien wird im Folgenden eingegangen.

#### 5.4.4.1. Detektionszeit

Die Detektionszeit ist die Zeitdauer zwischen dem aktiven Senden und der Detektion eines Kommandos. Bei den aktiven BCIs wurde der Zeitpunkt des Sendens anhand der Augenartefakte im EEG bestimmt, die bei der Augenbewegung zum Stimulus oder beim Schließen der Augen entstehen. Für das ERP-BCI lässt sich dieser Wert nicht bestimmen, da es sich um ein passives BCI handelt.

In der Abbildung 5.9 ist für jedes aktive BCI die Verteilung der ermittelten Werte über alle Probanden, alle Versuche und alle Geschwindigkeiten zu sehen. Augenartefakte ließen sich am schnellsten detektieren. In 75 % der Fälle stoppte der Cursor in unter einer Sekunde nach dem Schließen der Augen. Die Zeiten variierten nur gering. Die Detektion von Alphawellen erfolgte am zweitschnellsten. Unter Verwendung des Alphawellen-BCIs stoppte der Cursor in 75 % der Fälle in unter zwei Sekunden. Mit dem SSVEP-BCI fand der Stopp in 75 % der Fälle in unter drei Sekunden statt. Die Werte des Alphawellen-BCIs und des SSVEP-BCIs streuen stärker als die Werte des Augenartefakt-HMIs. Auch




Abbildung 5.9.: Detektionszeiten der Modalitäten zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Zeitdauern zwischen dem aktiven Senden und der Detektion eines Kommandos. Den Verteilungen liegen die Werte aller Probanden, aller Versuche und aller Geschwindigkeiten zugrunde.

kam es unter den beiden Modalitäten häufig zu Ausreißern. Die Ausreißer stellen jedoch nur einen geringen Teil der insgesamt aufgenommenen Messwerte dar.

#### 5.4.4.2. Zuverlässigkeit

Für jeden Probanden und jede Geschwindigkeit wurde ermittelt, wie oft der Cursor vor, über und hinter dem Ziel sowie überhaupt nicht gestoppt hat. Der Cursor stoppte über dem Ziel, sofern er das Ziel berührte. Hierüber lässt sich feststellen, wie zuverlässig die Modalitäten ein Stoppen des Cursors ermöglichen. In den Abbildungen 5.10 bis 5.13 sind für jede Modalität die Verteilungen der ermittelten Werte über alle Probanden zu sehen.

Wie in der Abbildung 5.10 zu sehen, ermöglichte das Alphawellen-BCI den Probanden stets ein Stoppen des Cursors. Da die Zeitdauer zwischen dem Schließen der Augen und dem Auftreten von Alphawellen nicht konstant ist, kam es mit zunehmender Geschwindigkeit zu einem häufigeren Stoppen hinter dem Ziel. Sowohl bei den niedrigen als auch bei den hohen Geschwindigkeiten kam es häufig zu einem Stoppen vor dem Ziel. Bei den hohen Geschwindigkeiten lässt sich dies ebenfalls mit der variierenden Zeitdauer bis




Abbildung 5.10.: Zuverlässigkeit des Alphawellen-BCIs zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Raten für ein Stoppen des Cursors vor, über und hinter dem Ziel sowie für ein nicht erfolgtes Stoppen.

zum Auftreten von Alphawellen begründen. Hingegen trat bei den niedrigen Geschwindigkeiten häufig ein Fehlalarm auf. Das liegt daran, dass ein Schließen der Augen zwar über die Analyse von Alphawellen festgestellt werden kann, jedoch kommt es ebenfalls zu einem Anstieg der Amplituden im Alphafrequenzbereich, sobald die Person entspannt oder müde ist. Mit der geringsten Geschwindigkeit benötigte der Cursor über eine Minute bis zum Ziel, wodurch die Probanden sehr lange auf ihren Einsatz warten mussten und dabei entspannten oder müde wurden. Bei der an MS erkrankten Probandin trat besonders häufig ein Fehlalarm auf, da sie aufgrund ihrer Krankheit besonders schnell ermüdet. Aufgrund der hohen Fehlalarmrate bei den niedrigen Geschwindigkeiten und dem unzuverlässigen Stoppen bei den hohen Geschwindigkeiten, liegt die höchste Rate für ein Stoppen über dem Ziel bei den mittleren Geschwindigkeiten.

Nicht jeder Proband konnte mit dem Augenartefakt-HMI den Cursor zu 100 % zum Stoppen bringen (siehe Abbildung 5.11). Wie in der Literatur bekannt, besitzen der Schädel und die Kopfhaut eine dämpfende Wirkung auf den Einfluss der Augenartefakte auf das EEG [37]. Mit zunehmender Dicke des Schädels und der Kopfhaut nehmen die Amplituden der Augenartefakte ab. Auch kann es zu einer Überlagerung der Augen-




Abbildung 5.11.: Zuverlässigkeit des Augenartefakt-HMIs zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Raten für ein Stoppen des Cursors vor, über und hinter dem Ziel sowie für ein nicht erfolgtes Stoppen.

artefakte mit anderen Artefakten kommen. Dies erschwerte bei einigen Probanden die Klassifikation von Augenartefakten und führte zu Versäumnissen bei der Detektion eines Schließens der Augen. Besonders bei hohen Geschwindigkeiten kam der Cursor nicht zum Stoppen, da hier die Zeit für eine Wiederholung des Kommandos zu gering war. Aufgrund der geringen Zeitdauer zwischen dem Schließen der Augen und dem Auftreten des Artefakts im EEG, kam es nur sehr selten zu einem Stoppen hinter dem Ziel. Die Zeitdauer variierte nur sehr gering, wodurch bei den hohen Geschwindigkeiten der Cursor kaum vor oder hinter dem Ziel stoppte. Verhielten sich die Probanden während des Experiments nicht sehr still, erzeugten sie andere Artefakte, die einen Fehlalarm auslösten. Besonders ein zu starkes und zu langes Blinzeln sowie ein gleichzeitiges Schlucken lösten ein Stopp-Kommando aus. In diesen Fällen glichen die auftretenden Signale denen bei einem Schließen der Augen. Je länger ein Versuch dauerte bzw. je geringer die Geschwindigkeit lag, umso größer war die Wahrscheinlichkeit für einen Fehlalarm. Hervorzuheben ist das Ergebnis der an MS erkrankten Probandin. Bei ihr stoppte der Cursor stets über dem Ziel, da durch ihre eingeschränkte Bewegungsfähigkeit nur wenige




Abbildung 5.12.: Zuverlässigkeit des SSVEP-BCIs zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Raten für ein Stoppen des Cursors vor, über und hinter dem Ziel sowie für ein nicht erfolgtes Stoppen.

unerwünschte Artefakte auftraten. Die höchste Rate für ein Stoppen über dem Ziel liegt bei der höchsten Geschwindigkeit, da Augenartefakte immer konstant und sehr schnell auftreten und die Wahrscheinlichkeit für eine Fehlklassifikation dort am geringsten ist.

Für das SSVEP-BCI ist eine sehr hohe Konzentration erforderlich. Während der Experimente blieb die Konzentration der Probanden nicht konstant. Dies führte zu stark variierenden Zeitintervallen zwischen der Aufmerksamkeitsverschiebung auf einen Stimulus und der Erzeugung von SSVEPs. Durch die nicht konstanten Zeitintervalle kam es häufig zu Stopps vor und hinter dem Ziel sowie zu einem völligen Ausbleiben von Stopps (siehe Abbildung 5.12). Mit zunehmender Geschwindigkeit wurden die Probanden nervös und es fiel ihnen schwerer, sich zu konzentrieren. Hierdurch variierten die Zeitintervalle noch stärker und die Raten der drei genannten Kategorien stiegen deutlich an. Bei der geringsten Geschwindigkeit kam es häufig zu einem Fehlalarm. Während der langen Wartezeit konnten viele Probanden ihren Blick nicht ruhig halten und richteten diesen zu nahe auf einen Stimulus, was eine SSVEP-Antwort auslöste und ein fehlerhaftes Stoppen zur Folge hatte. Mit der zweitkleinsten Geschwindigkeit wurden die häufigsten Stopps über dem Ziel erreicht, da hier die Probanden ausreichend Zeit




Abbildung 5.13.: Zuverlässigkeit des ERP-BCIs zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Raten für ein Stoppen des Cursors vor, über und hinter dem Ziel sowie für ein nicht erfolgtes Stoppen.

zur Konzentration erhielten und nicht nervös wurden. Außerdem war die Fehlalarmrate nicht so groß wie bei der geringsten Geschwindigkeit.

Ereigniskorrelierte Potenziale sind, aufgrund des sehr geringen Signal-Rausch-Abstandes, besonders schwer zu detektieren. Da eine Mittelung über mehrere Wiederholungen in diesem Fall nicht in Frage kommt, muss das Potenzial anhand eines einzigen Datensegmentes detektiert werden. Es wurde deshalb angenommen, dass die Zuverlässigkeiten des ERP-BCIs für ein Stoppen über dem Ziel sehr gering sind. Wie in der Abbildung 5.13 zu sehen, streuen die Werte sehr stark. Ein Viertel der Probanden erzielte Werte, die zwischen 60 und 100 % liegen. Die Leistungen dieser Probanden übertreffen die Erwartungen. Zu dieser Gruppe gehört auch die an MS erkrankte Probandin. Bei ihr traten nur sehr wenige Artefakte auf, die ein unerwünschtes Stoppen des Cursors zur Folge hatten. Die Ursache hierfür besteht in ihrer eingeschränkten Bewegungsfähigkeit. Aufgrund sehr hoher Fehlalarmraten, konnte die Mehrheit der Probanden den Cursor nicht über dem Ziel zum stoppen bringen. Mit zunehmender Geschwindigkeit nahmen die Fehlalarmraten ab. Bei der größten Geschwindigkeit stoppte der Cursor besonders oft hinter dem Ziel. Mit Ausnahme der geringsten Geschwindigkeit gab es bei allen anderen


Geschwindigkeiten Fälle, in denen der Cursor nicht stoppte. Die Ursache besteht darin, dass der Cursor passiv gestoppt wird und nicht durch ein aktives Senden eines Kommandos. Der Cursor stoppt nur, wenn er über dem Ziel ist und ein ereigniskorreliertes Potenzial auftritt. Ein gezieltes Stoppen nach Überschreitung des Zieles ist nur schwer durchzuführen. Aufgrund der hohen Fehlalarmrate bei den niedrigen Geschwindigkeiten und dem zu späten Stoppen bei den höchsten Geschwindigkeiten, liegt die höchste Rate für ein Stoppen über dem Ziel bei der zweitgrößten Geschwindigkeit.

##### 5.4.4.3. Genauigkeit


Zum Vergleich der Genauigkeiten wurden für jeden Probanden, jede Geschwindigkeit und jeden Versuch die Zielabweichung des gestoppten Cursors bestimmt. Die Abweichung wurde von der Mitte des Cursors bis zur Mitte des Zieles berechnet, da die Aufgabe darin bestand, den Cursor mittig über dem Ziel zu platzieren. Abweichungen bei einem Stoppen vor der Mitte des Zieles besitzen ein positives Vorzeichen. Stoppte der Cursor hinter der Mitte des Zieles, so besitzen die Abweichungen ein negatives Vorzeichen.

In der Abbildung 5.14 ist für jede Modalität und Geschwindigkeit die Verteilung der ermittelten Werte über alle Probanden und alle Versuche zu sehen. Die grüne gestrichelte Linie visualisiert den Zielfanfang und die rote gestrichelte Linie das Zielende. Liegen die Werte oberhalb der grünen Linie, stoppte der Cursor vor dem Ziel. Bei Werten unterhalb der roten Linie stoppte der Cursor hinter dem Ziel. Der Bereich zwischen den beiden Linien steht für einen Stopp über dem Ziel.


Wie in den Diagrammen zu sehen, nahmen die Fehlalarmraten mit abnehmender Geschwindigkeit und somit auch die betragsmäßigen Abweichungen vom Ziel zu. Lediglich beim SSVEP-BCI blieben die Zielabweichungen bei der niedrigsten Geschwindigkeit sehr gering. Mit zunehmender Geschwindigkeit konnte der Cursor unzuverlässiger über dem Ziel gestoppt werden. Die Folge war ein Anstieg der betragsmäßigen Abweichungen. Der Stopp erfolgte beim Alphawellen-BCI gleichmäßig oft vor oder hinter dem Ziel. Hingegen stoppte der Cursor beim SSVEP-BCI mit zunehmender Geschwindigkeit öfter




(a) Genauigkeit des Alphawellen-BCIs



(b) Genauigkeit des Augenartefakt-HMIs



(c) Genauigkeit des SSVEP-BCIs



(d) Genauigkeit des ERP-BCIs

Abbildung 5.14.: Genauigkeiten der Modalitäten zum Stoppen des Roboterarmes. Zu sehen sind die Verteilungen der Zielabweichungen des gestoppten Cursors. Den Verteilungen liegen die Abweichungen aller Probanden und aller Versuche zugrunde.



hinter dem Ziel. Aufgrund der besonders hohen Fehlalarmrate des ERP-BCIs, nahmen hier mit steigender Geschwindigkeit die betragsmäßigen Zielabweichungen ab. Lediglich unter Verwendung des Augenartefakt-HMIs stiegen die betragsmäßigen Abweichungen nur gering an und waren überwiegend sehr gering. Bei allen Modalitäten liegen sehr viele Ausreißer vor, welche jedoch nur einen geringen Teil der insgesamt aufgenommenen Messwerte darstellen.

##### 5.4.4.4. Fazit

Ein sicheres Stoppen (vor oder über dem Ziel) wurde bei allen Modalitäten mit den niedrigsten Geschwindigkeiten erzielt. Bei der niedrigsten Geschwindigkeit kam es jedoch häufig zu einem Fehlalarm, wodurch der Cursor oft sehr weit vor dem Ziel stoppte. Mit der höchsten Geschwindigkeit stoppte der Cursor oft hinter dem Ziel. Daher wurden die mittleren drei Geschwindigkeiten 7, 14 und 28 mm/s zur Roboterarmsteuerung eingesetzt.

Das Augenartefakt-HMI ermöglicht das schnellste und genaueste Stoppen des Cursors. Jedoch kann ein Stoppen nicht zu 100 % garantiert werden. Die Zuverlässigkeit des Alphawellen-BCIs ist am größten. Beide Modalitäten lassen sich optimal miteinander kombinieren, da beide auf einem Schließen bzw. Geschlossenhalten der Augen beruhen. Wird der Stopp in beiden Fällen ausgeführt, werden die Vorteile beider Modalitäten kombiniert. Zum Stoppen des Roboterarmes wurden daher das Alphawellen-BCI und das Augenartefakt-HMI benutzt. Zusätzlich ist ein Stoppen mit dem SSVEP-BCI möglich, indem der Nutzer entweder die Steuerungsgruppe verlässt oder die Richtungsvorgabe wiederholt. Ein Stoppen mit dem ERP-BCI ist sehr unzuverlässig und außerdem nur für einen geringen Personenkreis anwendbar. Daher wurde diese Modalität nicht zum Stoppen des Roboterarmes eingesetzt.

## **5.5. Test der geschwindigkeitsbasierten**

### **Roboterarmsteuerung**

In dieser Studie wurde die geschwindigkeitsbasierte Roboterarmsteuerung, anhand einer Pick-and-Place-Anwendung, getestet und unter objektiven und subjektiven Kriterien evaluiert. Das dabei verwendete Testszenario ist identisch mit dem Szenario, das bereits beim Testen der schrittweisen Roboterarmsteuerung Verwendung fand. Dies ermöglicht die Feststellung, ob die geschwindigkeitsbasierte Roboterarmsteuerung eine Verbesserung hinsichtlich des Zeitbedarfs und der benötigten Anzahl an Kommandos liefert.

Im Abschnitt 5.1 befindet sich eine Übersicht über das verwendete System. Wie bereits bei der schrittweisen Roboterarmsteuerung nutzten die Probanden das frequenzbasierte SSVEP-BCI (Abschnitt 4.2) als Umschalt- und Steuermodalität, die LEDs des sBCI-Helmes (Abschnitt 3.1) zur Stimulation und den 2-Tupel Zustandsautomaten (Abschnitt 4.4) zur Roboterarmsteuerung. Diese Konfiguration wurde im vorherigen Kapitel als am besten bewertet. Für die Regelung des Roboterarmes LWA 3 und des Greifers PG70 des Unternehmens Schunk, wurde erneut die in Abschnitt 4.5 beschriebene Implementierung eingesetzt. Zum Stoppen des Roboters an den Zielpositionen und in Gefahrensituationen nutzten die Probanden das Augenartefakt-HMI (Abschnitt 5.3) in Kombination mit dem Alphawellen-BCI (Abschnitt 5.2). Diese Kombination wurde im vorherigen Abschnitt als die schnellste und sicherste Methode bewertet.

#### **5.5.1. Versuchsteilnehmer**

Zwei weibliche und acht männliche Probanden nahmen an diesem Experiment teil. Das Alter der Probanden lag zwischen 18 und 33 Jahren, mit einem Durchschnittsalter von  $27,17 \pm 5,56$  Jahren. Alle Probanden hatten ein normales Sehvermögen oder trugen eine Sehhilfe. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse

beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung. Der Ethikausschuss der Universität Bremen erteilte die Genehmigung zur Durchführung des Experimentes. Vor dem Experiment erhielten die Probanden eine Informationsbroschüre und unterzeichneten eine Einverständniserklärung.

Die Versuche fanden in einem Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Dieses Labor besaß keine besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor dem 150 cm entfernten Roboterarm. Somit befanden sich die Probanden außerhalb des Arbeitsbereichs des Roboters.

### 5.5.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente zur Aufnahme der EEG-Signale. Das SSVEP-BCI nutzte 8 Elektroden ( $P_z$ ,  $PO_3$ ,  $PO_4$ ,  $PO_7$ ,  $PO_8$ ,  $O_z$ ,  $O_9$ ,  $O_{10}$ ) über dem visuellen Kortex. Sowohl das Alphawellen-BCI als auch das Augenartefakt-HMI verwendeten alle Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

### 5.5.3. Versuchsprotokoll

Vor dem Experiment mussten die Probanden dieselbe Kalibrierung wie beim Vergleich der Stoppmodalitäten (Abschnitt 5.4) durchführen. Alle vorherigen Einstellungen wurden in diesem Versuch übernommen. Wie beim Vergleich der Stoppmodalitäten festgestellt wurde, tritt bei der Verwendung des Augenartefakt-HMIs und des Alphawellen-BCIs häufig ein Fehlalarm auf. Ein zu starkes Blinzeln oder eine leichte Entspannung

führte oft zu einem fehlerhaften Senden eines Stopp-Kommandos. Daher wurde für beide Modalitäten ein empirisch ermittelter Schwellwert verwendet.

Im Anschluss an die Kalibrierung erhielten die Probanden eine Einweisung in die BCI-basierte Steuerung des Roboterarmes. Weiterhin konnten die Probanden den Roboter für ungefähr 10 Minuten frei steuern, um sich mit der Steuerung vertraut zu machen.

Sowohl der experimentelle Aufbau als auch die Aufgabenstellung dieses Experimentes waren dieselben, wie beim Test der schrittweisen Roboterarmsteuerung. Eine ausführliche Beschreibung ist dem Abschnitt 4.7.3 zu entnehmen. Im Rahmen einer Pick-and-Place-Anwendung mussten die Probanden zwei Würfel von einem Lego-Turm auf einen anderen Lego-Turm platzieren. Die Platzierung eines Würfels stellte eine Teilaufgabe dar. Beide Teilaufgaben mussten die Probanden direkt hintereinander ausführen. Der Versuch wurde von jedem der Probanden 2 Mal durchgeführt. Alle Versuche wurden überwacht und ein Notausschalter stand für unvorhersehbare Ereignisse zur Verfügung.

#### **5.5.4. Evaluierung**

Alle Teilnehmer der Studie waren in der Lage, über die entwickelte Schnittstelle, den Roboter zu steuern und die gestellten Aufgaben vollständig zu bearbeiten. Die gefahrenen Trajektorien sind ähnlich zu denen beim Test der schrittweisen Roboterarmsteuerung. Daher wird an dieser Stelle auf eine Darstellung verzichtet.

Sowohl subjektive als auch objektive Messungen wurden zur Evaluierung der Schnittstelle gesammelt. Die Bearbeitungszeit der Aufgabe und die dabei benötigte Anzahl an Umschalt- und Steuerkommandos dienen der objektiven Evaluierung. Um eine subjektive Evaluierung zu ermöglichen, beantworteten die Probanden den NASA-TLX-Fragebogen [68] und einen selbst entwickelten Fragebogen.




Abbildung 5.15.: Die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der ersten und zweiten Teilaufgabe.

#### 5.5.4.1. Objektive Evaluierung

Um eine minimale Referenzzeit spezifizieren zu können, wurden die kürzeste Trajektorie und die dafür notwendige Anzahl an Kommandos ermittelt. Ohne Berücksichtigung des Stopp-Kommandos, sind für die erste Teilaufgabe mindestens 26 Kommandos und für die zweite Teilaufgabe 24 Kommandos notwendig. Das Stopp-Kommando wird nicht berücksichtigt, da sich der Roboter während der Erzeugung des Kommandos noch fortbewegt. Die zu fahrende Strecke der ersten Teilaufgabe beträgt insgesamt 89 cm und die der zweiten Teilaufgabe 106 cm. Mit der geringsten Geschwindigkeit von 7 mm/s kann die Trajektorie der ersten Teilaufgabe in 127 s und die der zweiten Teilaufgabe in 151 s abgefahren werden. Da nach jedem Kommando eine Ruhephase von 2 s folgt, beträgt die minimale Zeit für die erste Teilaufgabe somit 2,98 Minuten und für die zweite Teilaufgabe 3,32 Minuten.

Die Abbildung 5.15 zeigt die von jedem Probanden im Mittel benötigten Zeiten zur Bearbeitung der beiden Teilaufgaben. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle C.3. Im Mittel benötigten die Probanden  $5,61 \pm 2,30$  Minuten für

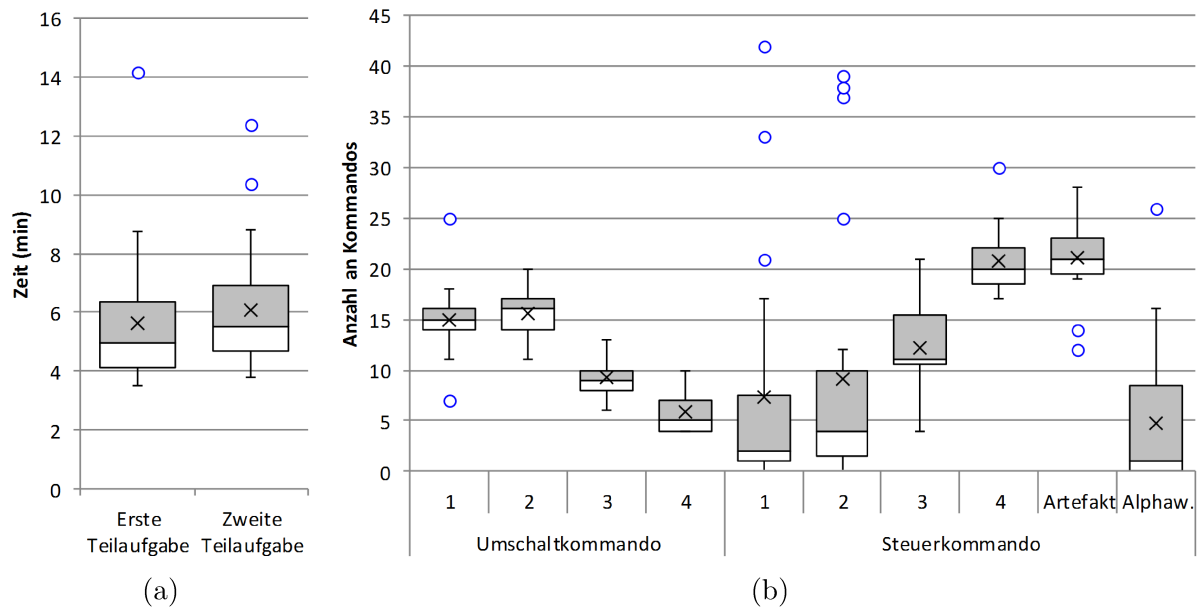


Abbildung 5.16.: Verteilungen der benötigten Zeiten für die erste und die zweite Teilaufgabe (a) und der benötigten Umschalt- und Steuerkommandos (b). Den Verteilungen liegen alle ermittelten Werte zugrunde.

die erste Teilaufgabe und  $6,06 \pm 2,05$  Minuten für die zweite Teilaufgabe. Am schnellsten bearbeitete Proband 1 die erste und die zweite Teilaufgabe (3,97 bzw. 4,06 Minuten). Dieser Proband konnte sehr schnell mit dem SSVEP-BCI Kommandos erzeugen und benötigte bereits mit der schrittweisen Roboterarmsteuerung eine geringe Bearbeitungszeit. Die anderen Probanden erzielten vergleichbare Zeiten, obwohl ihre Kommunikationsgeschwindigkeiten etwas niedriger lagen. Proband 6 und 10 benötigten auffällig viel Zeit zur Erzeugung von Kommandos und somit zur Bearbeitung der Aufgaben. Trotzdem waren beide Probanden in der Lage, den Roboterarm akkurat zu steuern und beide Durchläufe erfolgreich zu absolvieren.

In der Abbildung 5.16a sind die Verteilungen aller gemessenen Zeiten, für die erste und zweite Teilaufgabe, zu sehen. Die minimale Zeit für die erste Teilaufgabe liegt bei 3,48 Minuten und für die zweite Teilaufgabe bei 3,76 Minuten. Mit Ausnahme eines Ausreißers liegen alle Zeiten der ersten Teilaufgabe unter 8,78 Minuten und 75 % der Werte unter 6,34 Minuten. Für die zweite Teilaufgabe benötigten die Probanden etwas

mehr Zeit als für die erste Teilaufgabe. Hier liegen fast alle Zeiten unter 8,82 Minuten und 75 % der Werte unter 6,89 Minuten.

Abbildung 5.16b zeigt die Verteilungen der für beide Teilaufgaben benötigten Umschalt- und Steuerkommandos. Den Verteilungen liegen alle ermittelten Werte zugrunde. Wie in dem Diagramm zu sehen, wurden die Umschaltkommandos 1 und 2 am häufigsten verwendet. Da für die Bearbeitung der Aufgaben mehr Translationen als Rotationen erforderlich sind und das zweite Tupel Kommando für eine Translation immer eine 1 oder 2 sein muss, ist das Ergebnis zu erwarten gewesen. Am dritthäufigsten wurde das Kommando 3 für Rotationsbewegungen und ein Umschalten in die z-Achse benutzt. Das Umschaltkommando 4 wurde nicht sehr häufig in Verbindung mit einem Wechsel in die Gruppe des Greifers generiert.

Nur sehr selten benutzte die Hälfte aller Probanden die Steuerkommandos 1 und 2. Nach dem Stoppen des Roboters mussten diese Probanden kaum eine Korrektur vornehmen. Ein ungewolltes vorzeitiges Stoppen fand bei ihnen nicht statt. Bei der anderen Hälfte der Probanden gab es drei unterschiedliche Fälle zu beobachten, die oft in Kombination auftraten. Ein Proband steuerte den Roboter sehr vorsichtig und stoppte ihn vor jeder Geschwindigkeitsänderung ab. Vier Probanden benötigten viel Zeit zur Generierung der beiden Kommandos. Hierdurch kam es zu einer Müdigkeit der betreffenden Personen, die dazu führte, dass das Alphawellen-BCI ein Stopp-Kommando generierte und die Bewegung noch vor ihrer Ausführung verhinderte. Dies erklärt auch die hohe Anzahl des betreffenden Stopp-Kommandos für die Hälfte aller Werte. Zwei Probanden konnten während der Bewegungsausführung ihre Konzentration nicht von den LEDs abwenden und führten mit dem SSVEP-BCI ungewollte Stopps und Richtungsänderungen aus. Nach jeder Änderung der Geschwindigkeit, jedem Stoppen und jeder Richtungsänderung mussten diese Probanden den Roboter über die Steuerkommandos 1 und 2 starten oder die Richtung korrigieren. Die Anzahl des Steuerkommandos 1 liegt zwischen 0 und 17 und die des Steuerkommandos 2 zwischen 0 und 12. Eine Veränderung




Abbildung 5.17.: Verteilungen der gesamten Bearbeitungszeiten (a) und der benötigten Steuerkommandos (b) für den ersten und den zweiten Versuch. Den Verteilungen liegen alle ermittelten Werte zugrunde.

der Geschwindigkeit nahmen die Probanden unterschiedlich oft vor, was zu variierenden Bearbeitungszeiten geführt hat. Die Anzahl des Steuerkommandos 3 liegt zwischen 4 und 21. Wie oft die Probanden zwischen den Steuerungsgruppen umschalten mussten, ist über die benötigte Anzahl des Steuerkommandos 4 feststellbar. Je nach gewählter Trajektorie liegt die Anzahl zwischen 17 und 25. Vor jedem Wechsel der Gruppe erfolgte ein Stoppen des Roboterarmes, in der Regel mit Hilfe des Augenartefakt-HMIs (19 bis 28 Stopps) und nur selten über das Alphawellen-BCI (0 bis 16 Stopps). Die Ergebnisse bestätigen, dass ein sicheres Stoppen nur über die Kombination beider Modalitäten erreicht wird.

Einen Vergleich der gesamten Bearbeitungszeiten, für den ersten und den zweiten Versuch, liefern die Verteilungen in der Abbildung 5.17a. Den Verteilungen liegen alle ermittelten Zeiten zugrunde. Mit Ausnahme von drei Probanden konnten sich alle Teilnehmer zeitlich verbessern. Die Zeiten des ersten Versuchs liegen zwischen 7,90



und 17,61 Minuten und die des zweiten Versuchs zwischen 7,56 und 20,75 Minuten. Durchschnittlich verbesserten sich die Probanden um 1,45 Minuten.

Die Verteilungen in der Abbildung 5.17b zeigen die Veränderungen der benötigten Anzahl an Steuerkommandos. Den Verteilungen liegen alle ermittelten Werte zugrunde. Bei allen Steuerkommandos sind nur geringe Veränderungen ersichtlich. Einige Probanden konnten die Anzahl an Steuerkommandos 1 und 2 verringern, wohingegen die Anzahl bei anderen Probanden anstieg. Bei dem Steuerkommando 4 fällt auf, dass die Werte beim 2. Versuch höher sind und auch stärker streuen als beim 1. Versuch. Ein Teil der Probanden wurde während des 2. Versuchs müde und unkonzentriert und führte dadurch unnötige Wechsel der Steuerungsgruppe aus. Dies bestätigt der Anstieg der Stopp-Kommandos über das Alphawellen-BCI bei einigen Probanden, die in diesen Fällen durch Müdigkeit und nicht durch ein Schließen der Augen ausgelöst wurden.

Ein objektiver Vergleich der geschwindigkeitsbasierten mit der schrittweisen Steuerung erfolgt hinsichtlich des Zeitbedarfes und der benötigten Anzahl an Kommandos für die gesamte Aufgabe. Zum Vergleich der Messwerte beider Schnittstellen wurde ein Zweistichproben-t-Test für unabhängige Stichproben mit einem Signifikanzniveau von 5 % verwendet. Es wurden dabei ungleiche Varianzen angenommen. In der Abbildung 5.18 sind die Verteilungen der in allen Versuchen benötigten Zeiten und Kommandos beider Steuerungen dargestellt. Die Bearbeitungszeiten unter Verwendung der geschwindigkeitsbasierten Steuerung sind signifikant geringer als unter Verwendung der schrittweisen Steuerung. Im Durchschnitt benötigten die Probanden mit der geschwindigkeitsbasierten Steuerung 6,89 Minuten weniger Zeit als mit der schrittweisen Steuerung.

Da das Umschalten zwischen den Steuerungsgruppen bei beiden Ansätzen identisch ist, unterscheidet sich die Anzahl der benötigten Umschaltkommandos nur geringfügig. Hingegen ist bei der Anzahl der benötigten Steuerkommandos ein signifikant großer Unterschied ersichtlich. Für eine Steuerung in diskreten Schritten sind mehr als doppelt so

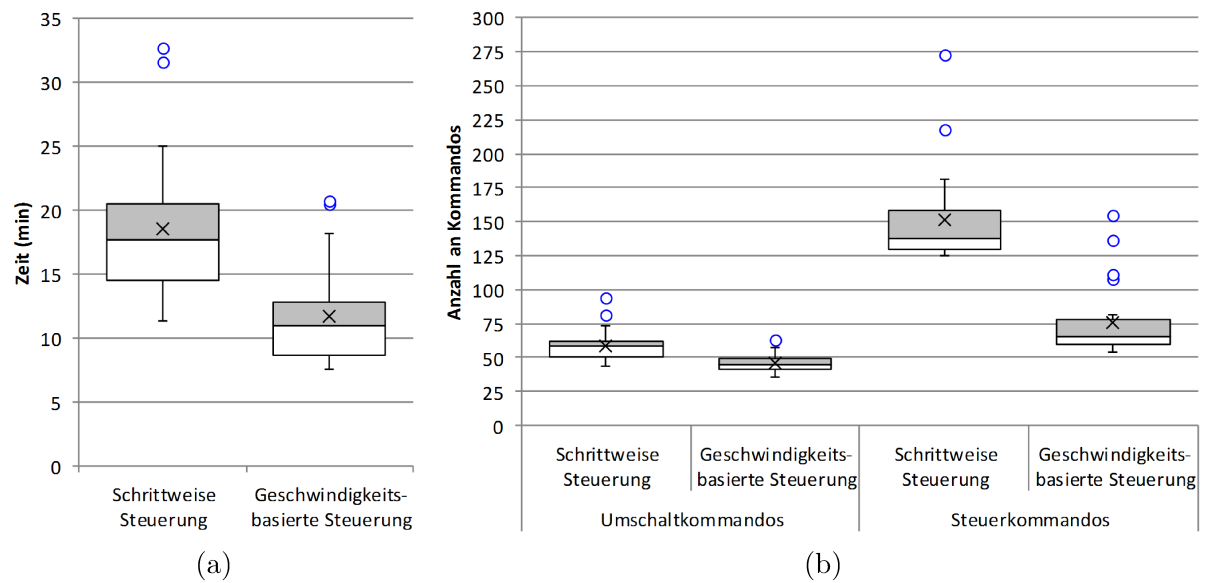


Abbildung 5.18.: Verteilungen der benötigten Zeiten (a) und der Umschalt- und Steuerkommandos (b) unter Verwendung der schrittweisen und der geschwindigkeitsbasierten Roboterarmsteuerung. Den Verteilungen liegen alle ermittelten Werte zugrunde.

viele Steuerkommandos notwendig als für eine Steuerung, in der eine Bewegung lediglich gestartet und gestoppt wird.

Zusammenfassend lässt sich feststellen, dass mit der geschwindigkeitsbasierten Steuerung weniger Kommandos notwendig sind, was zu einem geringeren Arbeitsaufwand des Nutzers führt und die Bearbeitungszeiten verkürzt.

#### 5.5.4.2. Subjektive Evaluierung

In der Abbildung 5.19 befinden sich die Ergebnisse der subjektiven Evaluierung anhand des NASA-TLX-Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde. Der Wertebereich des NASA-TLX-Fragebogens reicht von 0 (sehr gering) bis 100 (sehr hoch) für die Bewertung der mentalen, physischen und zeitlichen Anforderung sowie der Anstrengung und der Frustration. Die Leistungseinschätzung des Nutzers kann zwischen 0 (perfekt) und 100 (Misserfolg) liegen.




Abbildung 5.19.: Verteilungen der subjektiven Bewertungen anhand des NASA-TLX-Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.

Aufgrund der im Vergleich zur schrittweisen Steuerung geringeren Anzahl an benötigten Kommandos und der damit verbundenen schnelleren Bearbeitungszeit, wurde die mentale, physische und zeitliche Anforderung der Aufgabe als nicht sehr hoch empfunden. Die Mehrheit der Probanden bewertete alle drei Parameter mit einem Wert unter 20. Probanden, die sehr lange benötigten, um ein Kommando zu erzeugen, bewerteten die Anforderung, die Anstrengung und die Frustration deutlich höher als Probanden mit einer hohen Kommunikationsgeschwindigkeit. Außerdem bewerteten sie ihre Leistung negativer. Überwiegend empfanden die Probanden die Aufgabe nicht als frustrierend oder anstrengend und bewerteten ihre Leistung positiv.

Der selbst entwickelte Fragebogen nutzt die Likert-Skala [105], die von 1 (trifft gar nicht zu) bis 5 (trifft ganz zu) reicht. Die Ergebnisse dieser subjektiven Evaluierung befinden sich in der Abbildung 5.20. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.

Die Steuerungsgruppen, zur Veränderungen der Pose des Greifers und zum Greifen, wurden als sehr intuitiv bewertet. Hier konnten sich alle Probanden vorstellen, welche

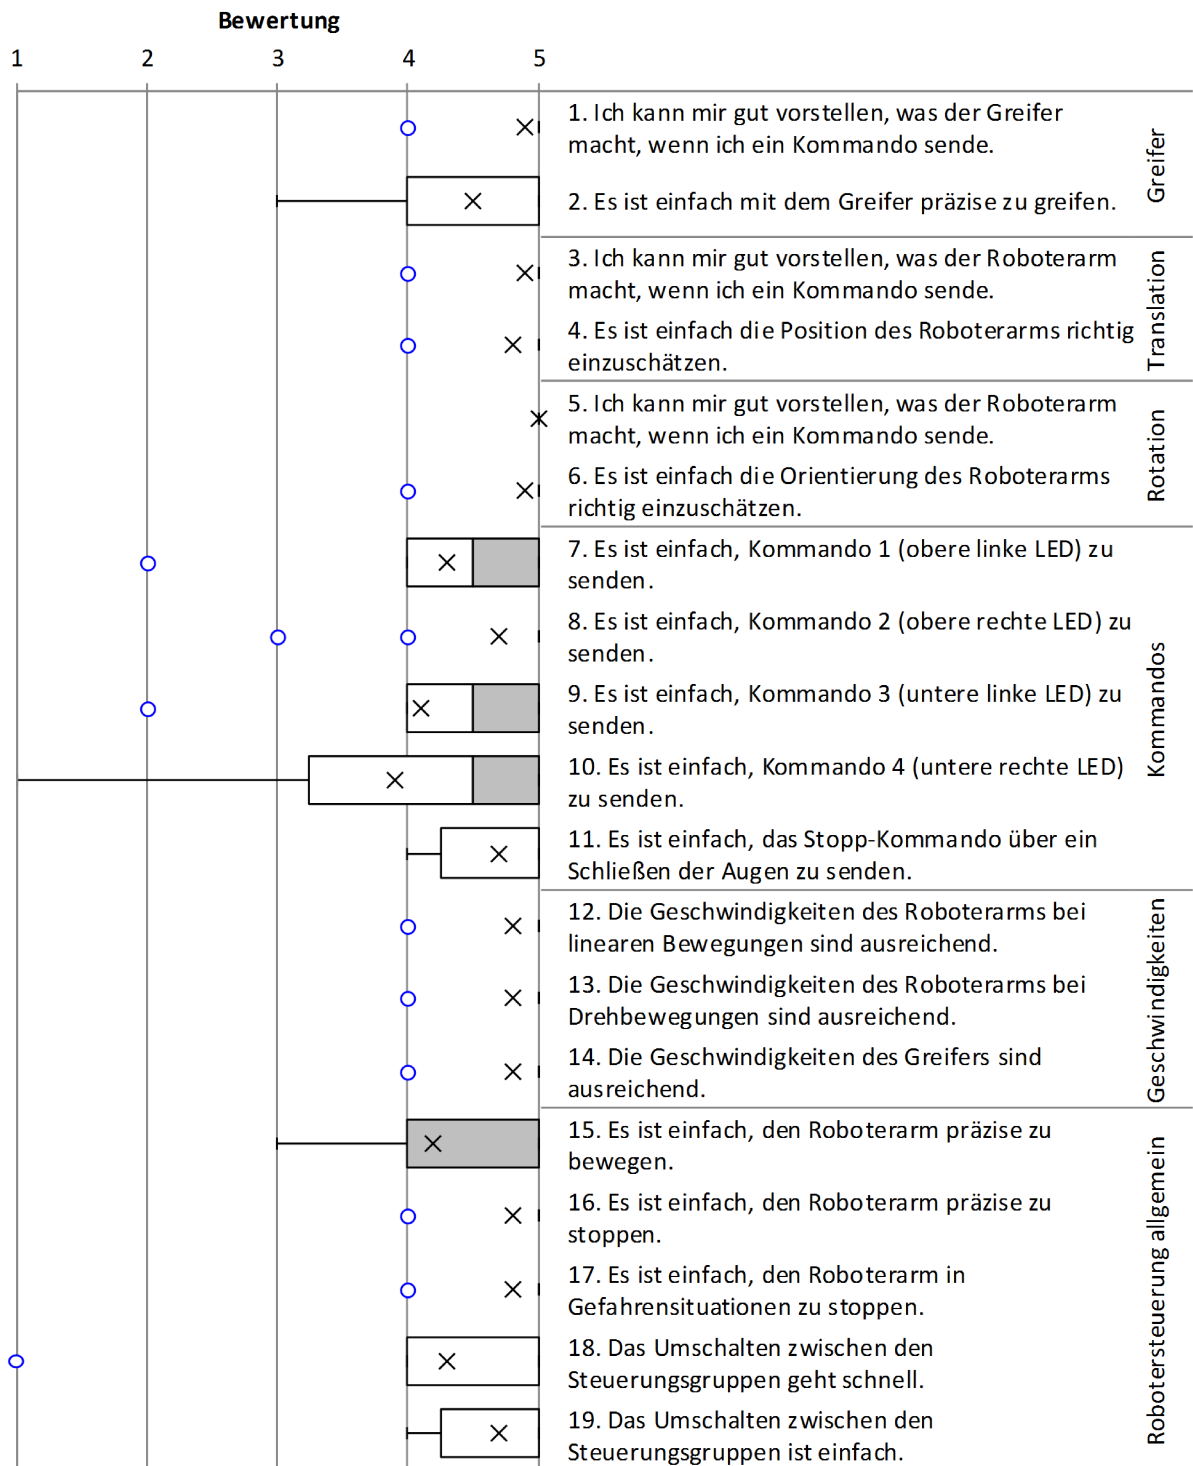


Abbildung 5.20.: Verteilungen der subjektiven Bewertungen anhand des selbst entwickelten Fragebogens. Den Verteilungen liegen die Bewertungen aller Probanden zugrunde.

Bewegung der Roboter ausführen wird, wenn sie ein Kommando senden. Alle Probanden konnten die Pose des Roboterarmes richtig einschätzen und mit dem Greifer präzise greifen.

Bereits bei der objektiven Evaluierung konnte festgestellt werden, dass die Kommunikationsgeschwindigkeit des SSVEP-BCIs von Nutzer zu Nutzer sehr unterschiedlich war und sich auf die Bearbeitungszeit der gestellten Aufgabe ausgewirkt hat. Dieser Umstand besitzt auch eine Auswirkung auf die subjektive Bewertung. Einige Probanden konnten sehr schnell SSVEP-Antworten erzeugen und empfanden es daher als leicht, Kommandos zu senden. Hingegen benötigten andere Probanden viel Zeit für die Erzeugung von SSVEP-Antworten und empfanden das Senden von Kommandos deshalb als schwierig. Da das Steuerkommando 4 besonders häufig verwendet wurde, erhielt dies die schlechteste Bewertung.

Die Geschwindigkeiten aller Bewegungen beurteilten die Probanden als ausreichend. Mit den Geschwindigkeiten sind präzise Bewegungen des Roboterarmes ausführbar. Sowohl an der Zielposition als auch in Gefahrensituationen kann der Roboter einfach und präzise über ein Schließen der Augen gestoppt werden. Ein Umschalten zwischen den Steuerungsgruppen ist mit dem 2-Tupel Zustandsautomaten nach nur drei Kommandos möglich und wurde als schnell und einfach bewertet.



## **Kapitel 6.**

# **Verfahren zur Detektion und Korrektur von Fehlern**

In diesem Kapitel werden Verfahren zur Detektion von Fehlern beschrieben, die innerhalb einer Roboterarmsteuerung auftreten. Fehler können bei der Navigation im Zustandsautomaten entstehen, wenn das System ein Kommando falsch detektiert und eine andere Aktion ausführt, als vom Nutzer beabsichtigt. Weiterhin können Fehler entstehen, wenn der Roboterarm nicht an der Zielposition stoppt. Beobachtet der Nutzer einen Fehler, entstehen Fehlerpotenziale im Gehirn, die im EEG feststellbar sind. Erkannte Klassifikationsfehler und Positionsabweichungen lassen sich dadurch detektieren und korrigieren.

Zu Beginn dieses Kapitels erfolgt eine Beschreibung des Systems zur Detektion und Korrektur von Fehlern, die bei der Navigation in einem Zustandsautomaten entstehen. Abschließend wird ein System vorgestellt, das ein Überschreiten der Zielposition feststellen und korrigieren kann.

### **6.1. Fehler bei der Navigation im Zustandsautomaten**

Dieser Abschnitt beschreibt das synchrone ErrP-BCI zur Detektion von Fehlern, die bei der Navigation im Zustandsautomaten der Roboterarmsteuerung auftreten. Klassifiziert das System ein Umschalt- oder Steuerkommando inkorrekt, wird ein anderes Kommando gesendet, als vom Nutzer beabsichtigt. Die Folge ist ein möglicher Wechsel in eine andere

Steuergruppe, ein Verlassen der Steuergruppe, eine Veränderung der Schrittweite oder Geschwindigkeit oder eine Bewegung des Roboterarmes. Der Nutzer realisiert den Fehler über die akustische Rückmeldung des Systems oder über eine Bewegung in eine falsche Richtung. Im Falle eines Fehlers treten im EEG Interaktions-Fehlerpotenziale auf. Die Detektion dieser Potenziale ermöglicht die Feststellung eines Fehlers und die Korrektur der fehlerhaften Aktionen. Das erste Umschaltkommando des 2-Tupel Zustandsautomaten wird im Falle eines Fehlers gelöscht. Bei einem fehlerhaften Wechsel oder Verlassen des Zustandes im Automaten, kehrt das System in den vorherigen Zustand zurück. Eine ungewollt geänderte Schrittweite oder Geschwindigkeit wird auf den vorherigen Wert zurückgesetzt. Führt der Roboter eine Bewegung in die falsche Richtung aus, nimmt der Roboter die vorherige Pose ein und verbleibt in dieser. Alternativ kann vor jeder Ausführung eines Kommandos dieses akustisch dem Nutzer mitgeteilt werden. Folgt der Rückmeldung ein Fehlerpotenzial, so wird das Kommando ignoriert.

Zu Beginn dieses Abschnittes erfolgt eine Beschreibung der Signalverarbeitung zur Detektion von Fehlerpotenzialen. Zum Schluss wird die Kalibrierung beschrieben, die Daten für den zu trainierenden Klassifikator aufnimmt. Kalibrierungsergebnisse von 13 Probanden liefern die Wahrscheinlichkeiten zur Detektion von Fehlern, die bei der Navigation im Zustandsautomaten entstehen.

### **6.1.1. Signalverarbeitung**

Im Jahre 2015 fand im Rahmen der siebten Neural Engineering (NER)-Konferenz ein Wettbewerb statt, der die Erkennung von Fehlerpotenzialen in einem P300-BCI zum Ziel hatte. Dieser Wettbewerb wurde von Alexandre Barachant und seinem Team gewonnen. Er nutzte den MDRM-Algorithmus in Kombination mit einer räumlichen Filterung.

Im Rahmen dieser Dissertation werden dieser Algorithmus, und der um eine zusätzliche Filterung erweiterte Klassifikator FGMDRM, zur Detektion von Fehlerpotenzialen verwendet. Die Verarbeitungsschritte sind identisch mit denen zur Detektion von Augenartefakten (siehe Abschnitt 5.3.1). Innerhalb der Vorverarbeitung findet ebenfalls eine



Bandpassfilterung zwischen 0,1 und 15 Hz statt. Der Algorithmus kann zwischen den beiden Klassen „Korrekt“ und „Fehler“ unterscheiden. Die erste Klasse steht für korrekt und die zweite Klasse für fehlerhaft erkannte Umschalt- und Steuerkommandos.

### 6.1.2. Kalibrierung

In diesem Abschnitt wird die Kalibrierung des ErrP-BCIs beschrieben. Die Kalibrierung dient der Aufnahme von nutzerspezifischen Daten für die Erstellung der räumlichen Filter und dem Training des Klassifikators. Während der Kalibrierung werden Trainingsdaten für korrekte und fehlerhafte Klassifikationen des Systems aufgenommen. Die Daten von 13 Probanden dienen einem Vergleich der beiden Klassifikatoren MDRM und FGMDRM und einer Evaluierung des ErrP-BCIs.

Zur Kalibrierung wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Über die im Rahmen dieser Arbeit entwickelte Anwendung wird der Ablauf der Kalibrierung gesteuert. Die Anwendung fordert den Probanden auf, einen Cursor über vier Richtungskommandos durch ein Labyrinth zu steuern. Mit einer vorher festgelegten Wahrscheinlichkeit führt der Cursor die gewünschte Bewegung korrekt aus. Um Daten für fehlerhafte Klassifikationen zu erhalten, wird andernfalls eine Bewegung in eine falsche Richtung ausgeführt. Der Proband erhält vor der Ausführung der Bewegung eine akustische Rückmeldung über das auszuführende Richtungskommando. Der Operator ermöglicht die Einstellung der Zeiten zum Senden eines Kommandos (Feedback-Intervall), die Zeiten für die Ankündigung und Ausführung des Kommandos (Post-Feedback-Intervall), die Wahrscheinlichkeiten für korrekte und fehlerhafte Aktionen und eine maximale Anzahl an Kommandos.

#### 6.1.2.1. Versuchsteilnehmer

Insgesamt wurden Kalibrierungsdaten von 13 Probanden aufgenommen. Die Gruppe bestand aus 5 Frauen und 8 Männern. Eine Probandin ist an MS erkrankt und vom Hals an abwärts gelähmt. Das Alter der Probanden lag zwischen 19 und 80 Jahren, mit einem Durchschnittsalter von  $30,77 \pm 18,17$  Jahren. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

#### 6.1.2.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente der Aufnahme von EEG-Signalen. Verwendet wurden alle 22 Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7 (Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

#### 6.1.2.3. Versuchsprotokoll

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte eine Stunde inklusive Erläuterung der Aufgabenstellung, Präparierung des sBCI-Helmes und dem Waschen der Haare. Jeder Proband musste den Cursor in 5 Durchläufen durch das Labyrinth steuern. Mit einer Wahrscheinlichkeit von 70 % führte der Cursor die




Abbildung 6.1.: Zeitlicher Ablauf zur Aufnahme von Fehlerpotenzialen. Während der Pre-Feedback-Phase wird der Proband kurz aufgefordert, eines der vier Richtungskommandos zu senden. Anschließend folgt die Feedback-Phase, in der der Proband das Kommando senden kann. In der darauffolgenden Post-Feedback-Phase wird die Bewegung des unteren Cursors angekündigt und ausgeführt. Mit einer festgelegten Wahrscheinlichkeit kann die Bewegung von der Intention des Nutzers abweichen. Der Durchlauf endet entweder nach Erreichen des Zieles oder einer maximalen Anzahl von Schritten.

geforderte Bewegung aus. Durchschnittlich benötigten die Probanden ca. 40 Kommandos für einen Durchlauf. Von den insgesamt ca. 200 Wiederholungen gehören somit ca. 140 Wiederholungen zu der Klasse „Korrekt“ und ca. 60 Wiederholungen zu der Klasse „Fehler“.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist in der Abbildung 6.1 zu sehen. Das Ziel des Probanden besteht darin, den unteren Cursor über die weißen Felder bis zum oberen Cursor zu steuern. In der Pre-Run-Phase erhält der Proband für 2 s Gelegenheit, sich auf den Durchlauf einzustellen. Anschließend wird in der 1 s langen Pre-Feedback-Phase der Proband akustisch und visuell dazu aufgefordert, eine der vier Richtungstasten zu drücken. Alternativ lässt sich der Cursor über das SSVEP-BCI aus Abschnitt 4.2 steuern. Dies ist für behinderte Probanden erforderlich, die ihre Hände nicht mehr bewegen können. Der Cursor kann sich nach oben, unten, links und rechts bewegen. Während der Feedback-Phase erhält der Proband ausreichend Zeit zum Senden eines Kommandos. Ein maximales Zeitfenster von 10 s ist sowohl für eine tastenbasierte Steuerung als auch für eine Steuerung mit dem SSVEP-BCI ausreichend. Nach der Detektion des Kommandos endet die Feedback-Phase vorzeitig. Es folgt die Post-Feedback-Phase von 3 s, in der die

Bewegung angekündigt und ausgeführt wird. Mit einer festgelegten Wahrscheinlichkeit kann die Bewegung von der Intention des Nutzers abweichen. Bei der Erzeugung von fehlerhaften Kommandos versucht das System nach Möglichkeit den Cursor nicht gegen eine Wand zu steuern. Der Durchlauf endet entweder nach Erreichen des Zieles oder einer maximalen Anzahl von 40 Schritten.

#### 6.1.2.4. Evaluierung

Die Evaluierung der aufgenommenen Daten erfolgte, für jeden Probanden einzeln, in Matlab mit einer  $10 \times 10$ -fachen stratifizierten Kreuzvalidierung. Hierzu wurden die Daten der beiden Klassen „Korrekt“ und „Fehler“ aus den Kalibrierungsaufnahmen extrahiert. Die Extraktion der Daten erfolgte mit einem Zeitfenster von 2 s. Jedes Daten-segment beginnt 0,25 s vor und endet 1,75 s nach dem Beginn der Rückmeldung. Der Algorithmus aus Abschnitt 6.1.1 diente der Verarbeitung der Signale. Für jede Klasse wurden vier räumliche Filter berechnet. Aufgrund der ausreichenden Anzahl an Datenpunkten, wurden die Kovarianzmatrizen empirisch geschätzt. Für jeden Probanden und jeden der beiden Klassifikatoren MDRM und FGMDRM wurden die ausgeglichene Klassifikationsgenauigkeit (BA), die Sensitivität (TPR), die Spezifität (TNR) und die Fläche unterhalb der ROC-Kurve (AUC) bestimmt. Die Klasse „Fehler“ bewirkt eine Korrektur seitens des Systems und ist daher die positive Klasse.

In der Abbildung 6.2 sind die zeitlichen und topografischen Darstellungen der Fehlerpotenziale eines Probanden zu sehen. Den Diagrammen liegen 140 Wiederholungen der Klasse „Korrekt“ und 60 Wiederholungen der Klasse „Fehler“ zugrunde. Fehlerpotenziale sind hauptsächlich über die frontalen Elektroden messbar. Wie in den Diagrammen zu sehen, tritt in den Kanälen des hinteren Bereichs des Gehirns der invertierte Signalverlauf der vorderen Kanäle auf. Zum Zeitpunkt 0 s erhielt der Proband eine Rückmeldung vom System. Im frontalen Bereich ist ein positiver Peak nach 340 ms zu sehen. Danach fallen die Amplituden leicht ab und erreichen nach 390 ms bei einer fehlerhaften Rückmeldung ein lokales Minimum und bei einer korrekten Rückmeldung erst nach 460 ms.

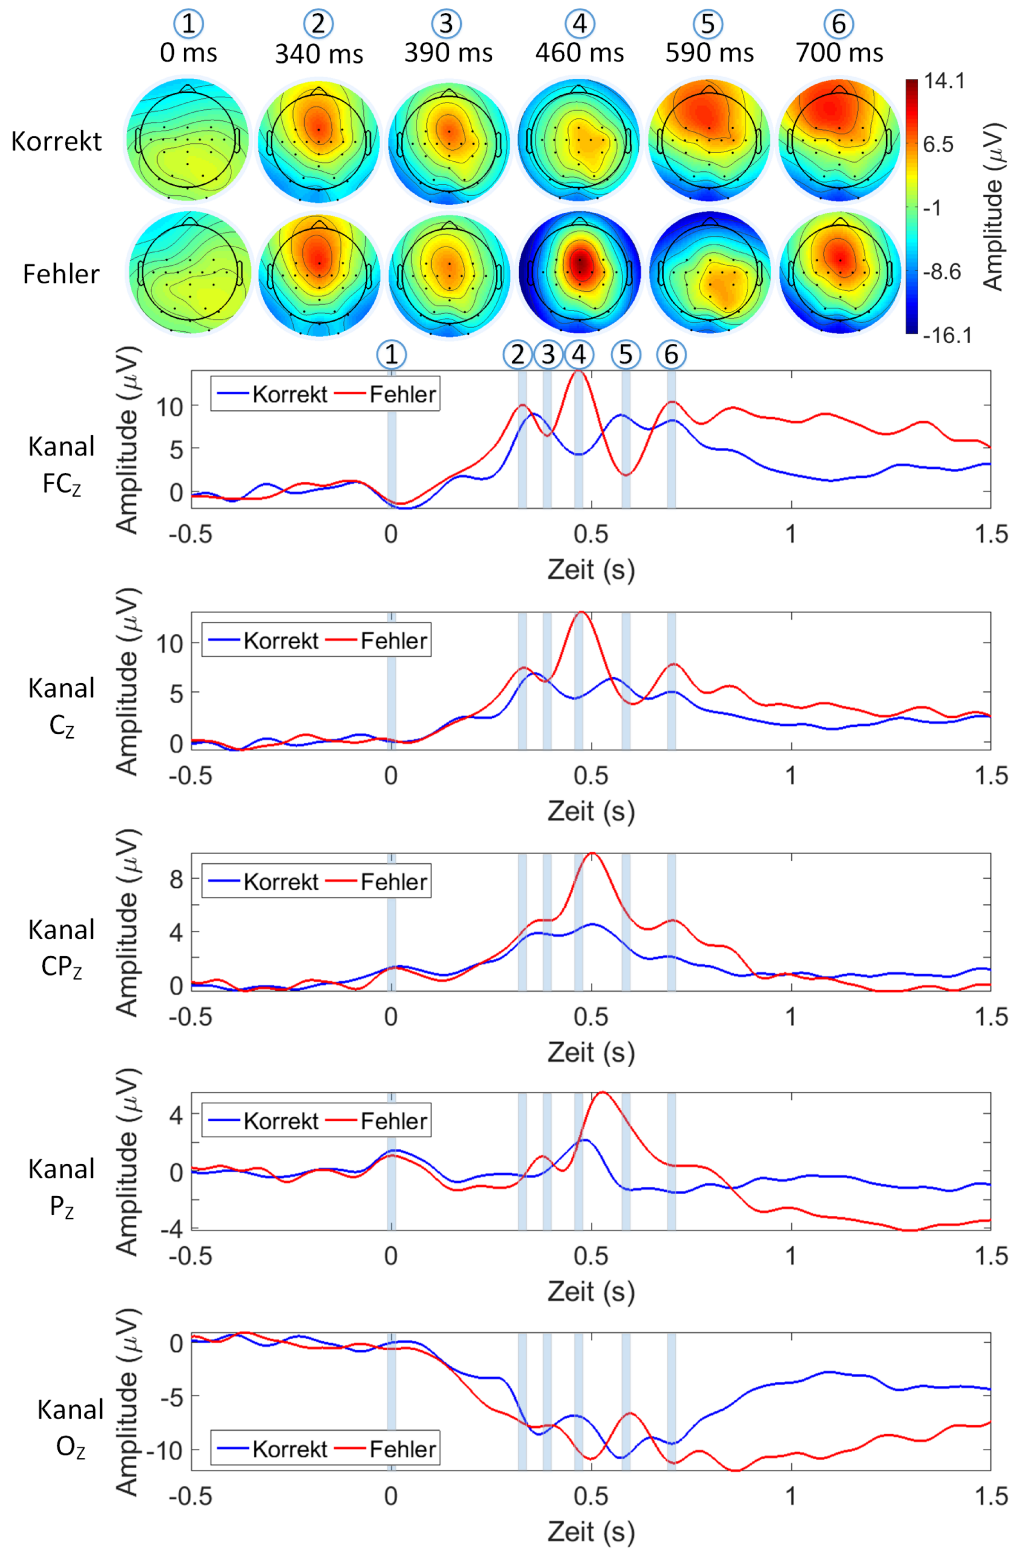


Abbildung 6.2.: Zeitliche und topografische Darstellung von Fehlerpotenzialen.




Abbildung 6.3.: Ergebnisse für die Klassifikation von Fehlern anhand von Fehlerpotenzialen. Den Verteilungen liegen die Ergebnisse aller Probanden zugrunde.

Im Falle eines Fehlers folgt ein positiver Peak, der sein Maximum nach 460 ms erreicht. Nach einer korrekten Rückmeldung wird das Maximum erst nach 590 ms erreicht. Zu diesem Zeitpunkt tritt im Fehlerfall ein letzter negativer Peak auf.

Die Abbildung 6.3 zeigt die Verteilungen der Klassifikationsergebnisse über alle Probanden. Die ausführlichen Ergebnisse befinden sich im Anhang in der Tabelle D.1. Wie in dem Diagramm zu sehen, liefert der Klassifikator FGMDRM bessere Ergebnisse als der Klassifikator MDRM. Die zusätzliche Filterung des FGMDRM-Algorithmus bewirkt eine Verbesserung der Klassifikationsergebnisse. Die mittlere Genauigkeit von MDRM liegt bei  $82,20 \pm 6,62$  % und von FGMDRM bei  $86,76 \pm 4,53$  %. Beim MDRM-Klassifikator liegen 75 % der Genauigkeiten über 76,20 % und beim FGMDRM-Klassifikator über 82,49 %. Die minimale und maximale Genauigkeit von MDRM liegt bei 73,35 % bzw. 94,30 % und die von FGMDRM bei 79,97 % bzw. 95,22 %. Bei den anderen Parametern verhält es sich ähnlich. Aufgrund der größeren Anzahl an Trainingsdaten für die negative Klasse, neigen beide Klassifikatoren zu einer Überanpassung an die entsprechende




Abbildung 6.4.: Wahrscheinlichkeitsbaum für ein BCI mit Fehlererkennung.

Klasse. Dies führt zu einer höheren Spezifität im Vergleich zur Sensitivität. Die an MS erkrankte Probandin (im Anhang als Proband 3 aufgeführt) erzielte eine Leistung im Bereich der Mittelwerte. Die Leistung des FGMDRM-Algorithmus ist vergleichbar mit den Werten, die der Literatur zu entnehmen sind (siehe Abschnitt 2.6.3).

Ob sich die Verwendung von Fehlerpotenzialen zur Fehlerkorrektur lohnt, hängt von der Klassifikationsgenauigkeit  $ACC_{\neg ErrP}$  des Paradigmas zum Umschalten und Steuern des Roboterarmes und von den Klassifikationswerten  $TPR$  und  $TNR$  des ErrP-BCIs ab. In der Abbildung 6.4 ist der Wahrscheinlichkeitsbaum für ein BCI mit Fehlererkennung zu sehen. Mit einer Wahrscheinlichkeit von  $ACC_{\neg ErrP}$  führt das System ein korrektes und mit der Gegenwahrscheinlichkeit  $1 - ACC_{\neg ErrP}$  ein falsches Kommando aus. Ein Fehlerpotenzial wird im Falle eines Fehlers mit einer Wahrscheinlichkeit von  $TPR$  detektiert. Jedoch wird mit der Gegenwahrscheinlichkeit  $1 - TPR$  kein Fehler detektiert. Im Falle keines Fehlers wird mit einer Wahrscheinlichkeit von  $TNR$  kein Fehlerpotenzial detektiert. Hingegen wird mit der Gegenwahrscheinlichkeit  $1 - TNR$  fälschlicherweise ein Fehler detektiert.

Anhand dieses Wahrscheinlichkeitsbaumes lässt sich für ein BCI mit Fehlererkennung die Veränderung der Leistung bestimmen. Wird nach der Detektion eines Fehlerpotenzials die Kommandoausführung rückgängig gemacht oder das angekündigte Kommando nicht ausgeführt, ergibt sich die neue Genauigkeit wie folgt [50]:

$$\begin{aligned}
 ACC_{\text{ErrP}} &= P(\neg \text{Fehler} | \neg \text{ErrP}) = \frac{P(\neg \text{ErrP} | \neg \text{Fehler}) \cdot P(\neg \text{Fehler})}{P(\neg \text{ErrP})} \\
 &= \frac{P(\neg \text{ErrP} | \neg \text{Fehler}) \cdot P(\neg \text{Fehler})}{P(\neg \text{ErrP} | \neg \text{Fehler}) \cdot P(\neg \text{Fehler}) + P(\neg \text{ErrP} | \text{Fehler}) \cdot P(\text{Fehler})} \\
 &= \frac{TNR \cdot ACC_{\neg \text{ErrP}}}{TNR \cdot ACC_{\neg \text{ErrP}} + (1 - TPR) \cdot (1 - ACC_{\neg \text{ErrP}})}.
 \end{aligned} \tag{6.1}$$

Die neue ITR, in Bits pro Trial, wird für ein BCI mit  $N$  Kommandos wie folgt berechnet [50]:


$$B_t = P' \left( \log_2 N + P \log_2 P + (1 - P) \log_2 \left( \frac{1 - P}{N - 1} \right) \right) \tag{6.2}$$

mit  $P = ACC_{\text{ErrP}}$  und  $P' = P(\neg \text{ErrP}) = TNR \cdot ACC_{\neg \text{ErrP}} + (1 - TPR) \cdot (1 - ACC_{\neg \text{ErrP}})$ .


Die Werte  $TPR$  und  $TNR$  des ErrP-BCIs variieren von Nutzer zu Nutzer. Das Diagramm in der Abbildung 6.5a zeigt die Veränderung der Genauigkeit für die minimalen, mittleren und maximalen Werte der zuvor ermittelten Parameter  $TPR$  und  $TNR$  des Klassifikators FGMDRM. Die Referenzlinie zeigt die Veränderung der Genauigkeit, wenn keine Fehlererkennung genutzt wird. In diesem Fall kommt es zu keiner Veränderung. Wie in der Abbildung zu sehen, ermöglicht die Fehlererkennung stets eine Verbesserung der Genauigkeit, da die drei Kurven oberhalb der Referenzlinie liegen. In dieser Hinsicht ist die Verwendung einer Fehlererkennung immer empfehlenswert.

Anhand der in Abbildung 6.5b gezeigten Verläufe der ITR (gemessen in Bits pro Wiederholung) für ein BCI mit 4 Kommandos wird deutlich, dass erst unterhalb einer bestimmten Genauigkeit eine Verbesserung der Kommunikationsgeschwindigkeit erzielt wird. Der Referenzverlauf zeigt die ITR für ein BCI ohne Fehlererkennung. Über den Schnittpunkt der drei Kurven mit der Referenzkurve lässt sich feststellen, ab welcher





(a) Veränderung der Genauigkeit



(b) Veränderung der ITR in Bits pro Wiederholung

Abbildung 6.5.: Veränderung der Leistung eines BCIs mit Fehlererkennung für die minimalen, maximalen und mittleren Werte der Parameter  $TPR$  und  $TNR$ .

Genauigkeit  $ACC_{\text{ErrP}}$  es zu einer Verbesserung der ITR kommt. Für die maximale  $TNR$  von 99,05 % und  $TPR$  von 91,40 % liegt der Schnittpunkt  $P1$  bei (99 %, 1,95 bits/trial). Bei der mittleren  $TNR$  von 93,86 % und  $TPR$  von 79,66 % liegt der Schnittpunkt  $P2$  bei (97 %, 1,77 bits/trial). Mit der minimalen  $TNR$  von 89,76 % und  $TPR$  von 70,19 % liegt der Schnittpunkt  $P3$  bei (93 %, 1,54 bits/trial). Liegen die Genauigkeiten rechts von den Schnittpunkten, kommt es trotz der verbesserten Genauigkeit zu einer Verschlechterung der ITR. Erst bei Genauigkeiten links von den Schnittpunkten liegt eine Verbesserung vor. Die Genauigkeiten eines frequenzbasierten SSVEP-BCIs und eines P300-BCIs liegen im Mittel bei ca. 98 % (siehe Abschnitt 4.6). Für die mittleren und maximalen Werte scheint daher die Verwendung des ErrP-BCIs empfehlenswert.

Die ITR in Bits pro Wiederholung berücksichtigt jedoch nicht die zusätzlich benötigte Zeit zur Fehlerkorrektur oder zur Ankündigung des auszuführenden Kommandos. In der Abbildung 6.6 sind daher für die maximalen Werte mehrere Verläufe der ITR in Bits pro Minute zu sehen. Bei der Berechnung der Referenzkurve eines BCIs ohne Fehlererkennung wurde ein Zeitintervall von 2 s zwischen zwei aufeinanderfolgenden Kommandos angenommen. Die übrigen Kurven zeigen die Verläufe der ITR für ein BCI mit Fehlererkennung. Hierbei wurden Zeitintervalle zwischen 2 und 4 s angenommen. Auch hier geben die Schnittpunkte Aufschluss darüber, ab welcher Genauigkeit eine Verbesserung der ITR eintritt. Der Schnittpunkt  $P1$  liegt bei (100 %, 59,43 bits/min) und beschreibt den unrealistischen Fall, dass keine zusätzliche Zeit zur Fehlererkennung und -korrektur benötigt wird. In diesem Fall führt die Verwendung eines ErrP-BCIs fast immer zu einer Verbesserung der Leistung. Unter der Annahme einer zusätzlich benötigten Zeitdauer von 0,5 s liegt der Schnittpunkt  $P2$  bei (90 %, 41,19 bits/min). Diese Zeitdauer wird mindestens benötigt, wodurch die entsprechende Kurve den realistischen Idealfall beschreibt. Die Schnittpunkte  $P3$ ,  $P4$  und  $P5$  liegen bei (81 %, 29,92 bits/min), (74 %, 22,80 bits/min) und (69 %, 18,21 bits/min) und berücksichtigen größere Zeitintervalle. Das in dieser Arbeit entwickelte SSVEP-BCI würde in keinem realistischen Fall von einer Fehlererkennung profitieren. Hingegen würde ein ERD/ERS-BCI sogar




Abbildung 6.6.: Die ITR in Bits pro Minute für die maximalen Werte der Parameter  $TPR$  und  $TNR$  und für verschiedene Zeitintervalle zwischen zwei aufeinanderfolgenden Kommandos.

bei größeren Zeitintervallen von einer Fehlererkennung profitieren. Beim Training von Bewegungsvorstellungen erreichten viele Probanden Genauigkeiten deutlich unter 81 % (siehe Abschnitt 3.3.3). Im Rahmen dieser Dissertation wurde auf eine Fehlererkennung bei der Navigation im Zustandsautomaten verzichtet, da das SSVEP-BCI als Umschalt- und Steuermodalität für die Roboterarmsteuerung verwendet wurde.

## 6.2. Fehler durch Zielabweichungen bei einer aktiven und passiven Steuerung

Dieser Abschnitt beschreibt das asynchrone ERP-BCI zur Detektion der Zielpositionen und zur Feststellung von Zielabweichungen bei einer Roboterarmsteuerung. Erreicht der Greifer eines Roboterarmes die vom Nutzer gewünschte Zielposition, treten im EEG er-

eigniskorrelierte Potenziale auf. Durch die Feststellung dieser Potenziale wird der Roboter an der Zielposition zum Stoppen gebracht. Überschreitet der Greifer die Zielposition und kommt nicht zum Halt, treten im EEG Fehlerpotenziale auf. Nach der Detektion dieser Potenziale wird, anhand der Geschwindigkeit des Roboters und der vergangenen Zeit seit dem Auftreten des Potenzials, die Zielposition bestimmt. Hierüber ist anschließend eine Korrektur der Zielabweichung möglich. Ein Fehlerpotenzial nach einem fehlerhaften Stopp wird nicht genutzt, da nicht festgestellt werden kann, ob der Stopp vor oder hinter dem Ziel erfolgte. Je nach Einbindung des Nutzers in die Steuerung treten die Potenziale unterschiedlich stark auf. Sendet der Nutzer aktiv ein Kommando (z.B. mit einem SSVEP-BCI), sind die Amplituden der Potenziale größer als bei einer passiven Steuerung, in der der Roboterarm nur beobachtet wird.

Zu Beginn dieses Abschnittes erfolgt eine Beschreibung der Signalverarbeitung zur Detektion von ereigniskorrelierten Potenzialen. Zum Schluss wird die Kalibrierung beschrieben, die Daten für den zu trainierenden Klassifikator aufnimmt. Kalibrierungsergebnisse einer aktiven und passiven Steuerung von jeweils 10 Probanden werden präsentiert, die aufzeigen, mit welchen Wahrscheinlichkeiten ein Stopp an der Zielposition und ein Überschreiten der Zielposition detektiert werden kann.

### **6.2.1. Signalverarbeitung**

Zur Detektion von ereigniskorrelierten Potenzialen werden die beiden Klassifikatoren MDRM und FGMDRM verwendet. Die Verarbeitungsschritte sind identisch mit denen zur Detektion von Augenartefakten (siehe Abschnitt 5.3.1). Innerhalb der Vorverarbeitung findet ebenfalls eine Bandpassfilterung zwischen 0,1 und 15 Hz statt. Der Algorithmus kann zwischen den drei Klassen „Ruhephase“, „Am Ziel gestoppt“ und „Am Ziel vorbei“ unterscheiden. Die Ruhephase muss berücksichtigt werden, da die Zielposition dem System nicht bekannt ist und das System daher asynchron operieren muss.

### 6.2.2. Kalibrierung

In diesem Abschnitt wird die Kalibrierung des ERP-BCIs beschrieben. Die Kalibrierung dient der Aufnahme von nutzerspezifischen Daten für die Erstellung der räumlichen Filter und dem Training der Klassifikatoren. Während der Kalibrierung werden Trainingsdaten für Stopps an der Zielposition und für ausbleibende Stopps aufgenommen. Die Zeitintervalle vor dem Erreichen der Zielposition gehören zu der Ruhephase. Die Daten einer aktiven und passiven Steuerung von jeweils 10 Probanden dienen einer Evaluierung des ERP-BCIs.

Zur Kalibrierung wird das BCI2000-Framework [156] verwendet. Dieses besteht aus vier Modulen: Signalaufnahme, Signalverarbeitung, Anwendung und Operator. Die Aufnahme und Filterung der Signale erfolgt mit dem Signalaufnahmemodul. Während der Kalibrierung ist keine Signalverarbeitung notwendig, weshalb das entsprechende Modul die Signale einfach weiterleitet. Über die im Rahmen dieser Arbeit entwickelte Anwendung wird der Ablauf der Kalibrierung gesteuert. Während der Kalibrierung bewegt sich ein Cursor vom linken bis zum rechten Bildschirmrand mit einer konstanten Geschwindigkeit. Der Proband erhält die Aufgabe, den Cursor über einem definierten Ziel zum Stoppen zu bringen. Bei der aktiven Steuerung muss der Proband rechtzeitig ein Stopp-Kommando senden. Hingegen sendet der Proband bei der passiven Steuerung kein explizites Kommando. Mit vorher festgelegten Wahrscheinlichkeiten führt der Cursor einen Stopp über der Zielposition aus oder bewegt sich über das Ziel hinaus. Ein Stoppen des Cursors wird dem Probanden akustisch und visuell mitgeteilt. Der Operator ermöglicht die Einstellung der Geschwindigkeit des Cursors (Feedback-Intervall), der Zeiten zur Anzeige der Ziel- und der Stoppposition (Pre-Feedback- und Post-Feedback-Intervall) und der Wahrscheinlichkeit für einen Stopp an der Zielposition.

Tabelle 6.1.: Informationen über die Probanden, die an der Kalibrierung der aktiven und passiven Steuerung teilnahmen.

Art der Steuerung	Geschlecht		Alter			
	weibl.	männl.	Min.	Max.	Mittelw.	SD
passiv	4	6	19	80	33,30	20,31
aktiv	3	7	19	80	29,40	18,19

### 6.2.2.1. Versuchsteilnehmer

Insgesamt wurden für die aktive und passive Steuerung Kalibrierungsdaten von jeweils 10 Probanden aufgenommen. Die Informationen über die Versuchsteilnehmer, hinsichtlich Geschlechts und Alters, sind der Tabelle 6.1 zu entnehmen. Eine Probandin ist an MS erkrankt und vom Hals an abwärts gelähmt. Sie testete nur die passive Steuerung, da sie für eine aktive Steuerung das SSVEP-BCI benutzen müsste. Aufgrund einer starken Beeinträchtigung der Sehfähigkeit konnte sie dieses jedoch nicht nutzen. Laut Selbstaussage hatte keiner der Teilnehmer eine Vorgeschichte von neurologischen oder psychiatrischen Erkrankungen, die die experimentellen Ergebnisse beeinflusst haben könnten. Die Teilnehmer der Studie waren Studenten und Mitarbeiter der Universität Bremen. Für ihre Teilnahme erhielten die Probanden keine Aufwandsentschädigung.

Die Aufnahmen fanden im BCI-Labor des Instituts für Automatisierungstechnik (IAT) an der Universität Bremen statt. Bei diesem Labor handelt es sich um einen normalen Büroraum ohne besondere Abschirmung gegen Geräusche oder andere Störquellen. Die Nutzer saßen in einem verstellbaren Stuhl vor einem 80 cm entfernten Computermonitor.

### 6.2.2.2. Datenaufnahme

Der in Abschnitt 3.1 beschriebene sBCI-Helm diente der Aufnahme von EEG-Signalen. Verwendet wurden alle 22 Elektroden des Helmes. Als Ground-Elektrode diente die Elektrode  $AF_z$  an der Stirn. Durch ein Elektrolytgel wurden die Impedanzen auf unter 5 k $\Omega$  gebracht. Die Aufnahme der EEG-Signale erfolgte über den Verstärker Porti 7

(Abschnitt 3.1) mit einer Abtastrate von 256 Hz. Alle Signale wurden mit einem Hochpassfilter (0,1 Hz Grenzfrequenz) und einem Kerbfilter (50 Hz) vorverarbeitet.

### 6.2.2.3. Versuchsprotokoll

Die Probanden nahmen an einer einzigen Kalibrierungssitzung teil. Die Sitzung dauerte eine Stunde inklusive Erläuterung der Aufgabenstellung, Präparierung des sBCI-Helms und dem Waschen der Haare. Insgesamt musste jeder Proband 3 Durchläufe absolvieren. Jeder Durchlauf bestand aus 30 Wiederholungen. Der Cursor bewegte sich in jeder Wiederholung vom linken bis zum rechten Bildschirmrand. Die Probanden mussten entweder auf passivem oder aktivem Wege den Cursor mittig über dem Ziel zum Stoppen bringen. Mit einer Wahrscheinlichkeit von 70 % führte der Cursor den geforderten Stopp aus. Von den insgesamt 90 Wiederholungen gehören somit 63 Wiederholungen zu der Klasse „Am Ziel gestoppt“ und 27 Wiederholungen zu der Klasse „Am Ziel vorbei“.

Der zeitliche Ablauf eines Kalibrierungsdurchlaufs ist ähnlich zu dem Testablauf der Stoppmodalitäten aus Abschnitt 5.4 (siehe Abbildung 5.8). Die Anwendung startet mit der Pre-Run-Phase, in der der Proband für 2 s Gelegenheit erhält, sich auf den Durchlauf einzustellen. Anschließend wird in der Pre-Feedback-Phase für 3 s das Ziel angezeigt. Innerhalb der 6 s langen Feedback-Phase bewegt sich der Cursor vom linken bis zum rechten Bildschirmrand. Bei der aktiven Steuerung muss der Proband eine Taste drücken, sobald sich der Cursor mittig über dem Ziel befindet. Alternativ lässt sich der Cursor über das SSVEP-BCI aus Abschnitt 4.2 stoppen. Dies ist für behinderte Probanden erforderlich, die ihre Hände nicht mehr bewegen können. Hingegen muss bei der passiven Steuerung lediglich der Cursor beobachtet und gedanklich ein Stoppen gefordert werden. Mit einer festgelegten Wahrscheinlichkeit stoppt der Cursor an der Zielposition oder bewegt sich weiter bis zum rechten Bildschirmrand. Sobald der Cursor über dem Ziel stoppt oder den rechten Bildschirmrand erreicht hat, beginnt die Post-Feedback-Phase mit einer Dauer von 3 s. Hier wird dem Probanden die Endposition des Cursors angezeigt. Ein Stoppen des Cursors wird dem Probanden akustisch und visuell mitgeteilt.

Dieser Ablauf wird mehrfach hintereinander wiederholt, damit für jede Klasse genügend Trainingsdaten vorliegen.

#### 6.2.2.4. Evaluierung

Die Evaluierung der aufgenommenen Daten erfolgte, für jeden Probanden einzeln, in Matlab mit einer  $10 \times 10$ -fachen stratifizierten Kreuzvalidierung. Hierzu wurden die Daten der drei Klassen „Ruhephase“, „Am Ziel gestoppt“ und „Am Ziel vorbei“ aus den Kalibrierungsaufnahmen extrahiert. Die Extraktion der Daten erfolgte mit einem Zeitfenster von 2 s. Jedes Datensegment der beiden letzten Klassen beginnt 0,25 s vor und endet 1,75 s nach dem Erreichen des Zieles. Für die erste Klasse wurden die Daten zwischen der ersten Sekunde nach dem Start des Cursors und 0,25 s vor dem Erreichen des Zieles verwendet. Innerhalb dieses variablen Zeitfensters erfolgte die Extraktion alle 125 ms. Der Algorithmus aus Abschnitt 6.2.1 diente der Verarbeitung der Signale. Für jede Klasse wurden vier räumliche Filter berechnet. Aufgrund der ausreichenden Anzahl an Datenpunkten, wurden die Kovarianzmatrizen empirisch geschätzt. Für jeden Probanden und jeden der beiden Klassifikatoren MDRM und FGMDRM wurden die ausgeglichene Klassifikationsgenauigkeit (BA), die Sensitivität (TPR) und die Spezifität (TNR) bestimmt. Dabei wurden entweder die Klasse „Am Ziel vorbei“, die Klasse „Am Ziel gestoppt“ oder beide Klassen zusammen als die positive Klasse betrachtet. Alle übrigen Klassen bildeten zusammen die negative Klasse.

In den Abbildungen 6.7 und 6.8 sind die zeitlichen und topografischen Darstellungen von ereigniskorrelierten Potenzialen eines Probanden zu sehen, der einen Cursor auf passive oder aktive Weise gestoppt hat. Den Diagrammen liegen jeweils 63 Wiederholungen der Klasse „Am Ziel gestoppt“ und 27 Wiederholungen der Klasse „Am Ziel vorbei“ zugrunde.

Bei einer passiven Steuerung tritt im zentralen Bereich des Gehirns (Elektroden  $C_z$  und  $CP_z$ ) ein negativer Peak auf, sobald der Cursor die Zielposition erreicht hat. Es folgt ein Anstieg der Signale. Im frontalen Bereich (Elektrode  $FC_z$ ) ist der Anstieg bei



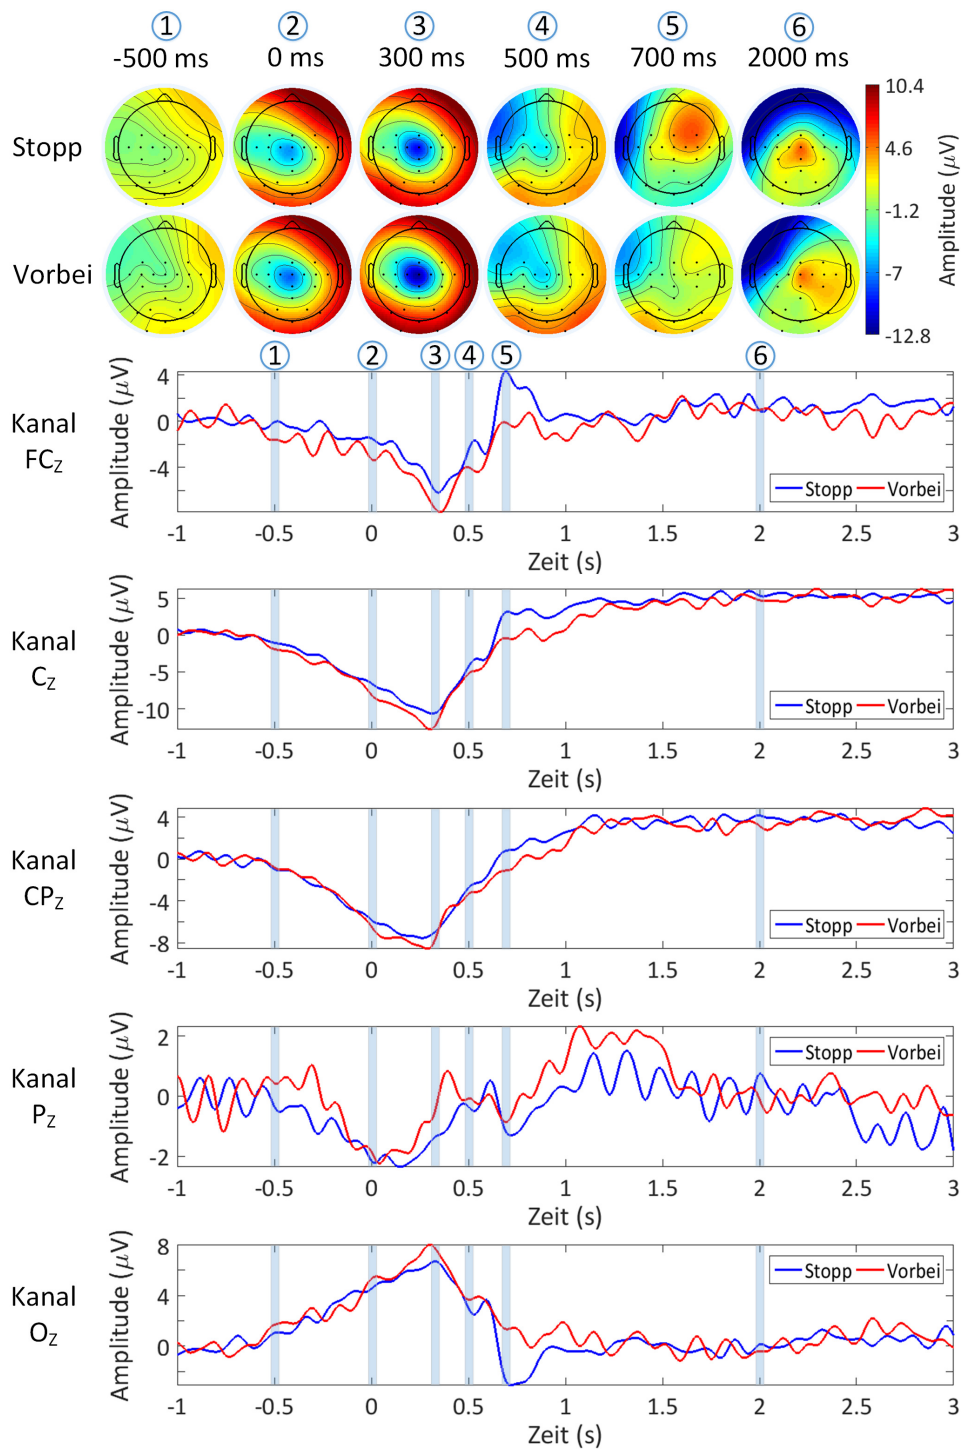


Abbildung 6.7.: Zeitliche und topografische Darstellung von ereigniskorrelierten Potentialen bei einer passiven Steuerung.

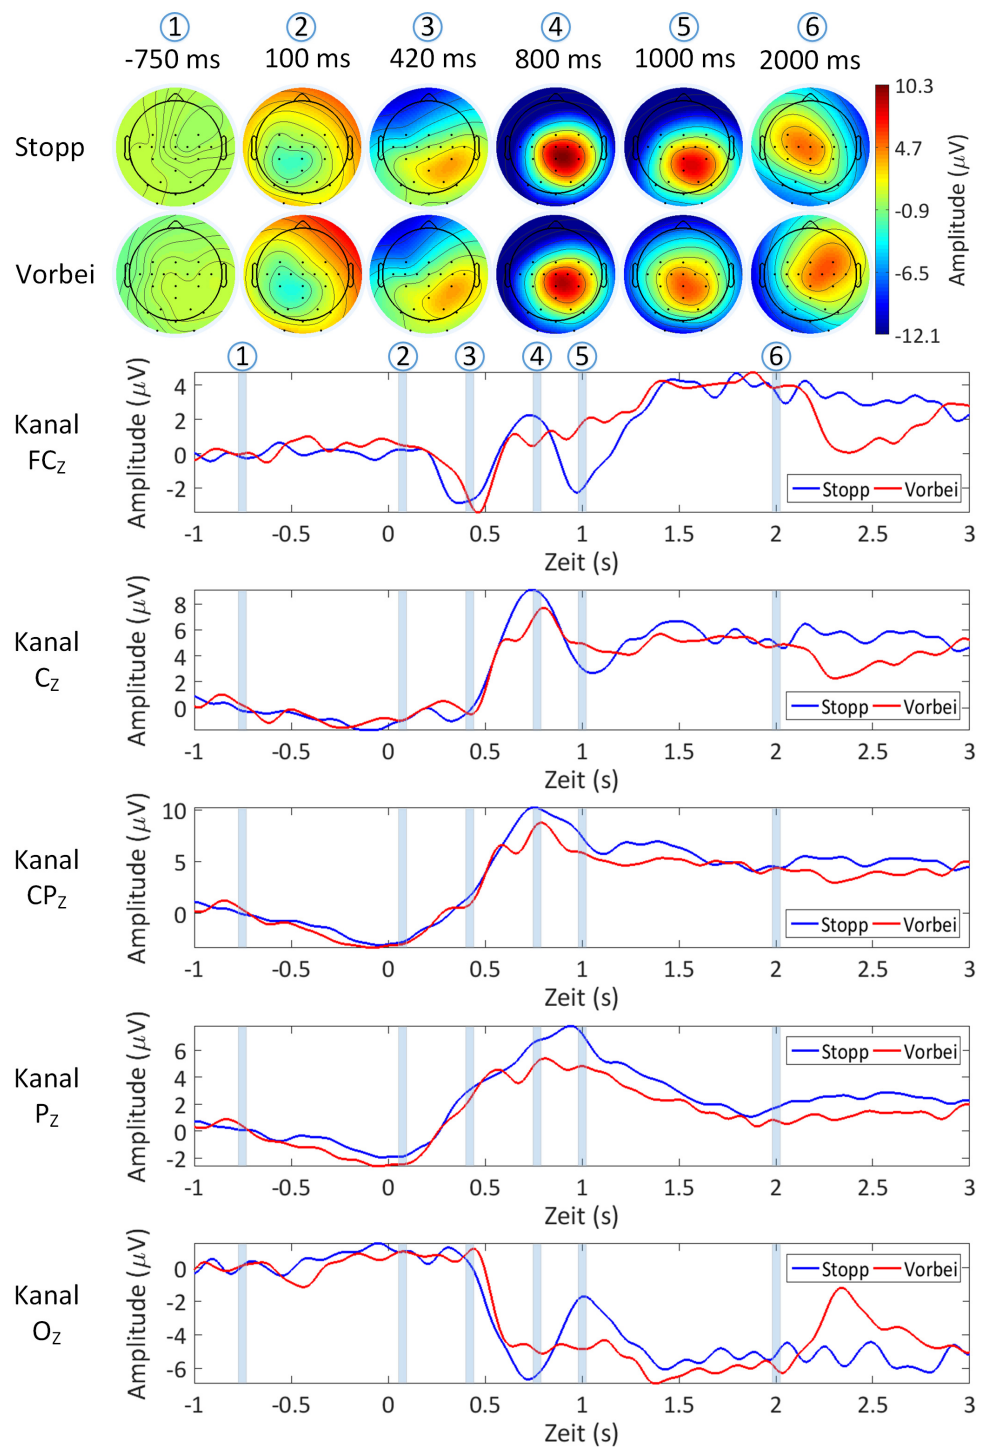



Abbildung 6.8.: Zeitliche und topografische Darstellung von ereigniskorrelierten Potentialen bei einer aktiven Steuerung.

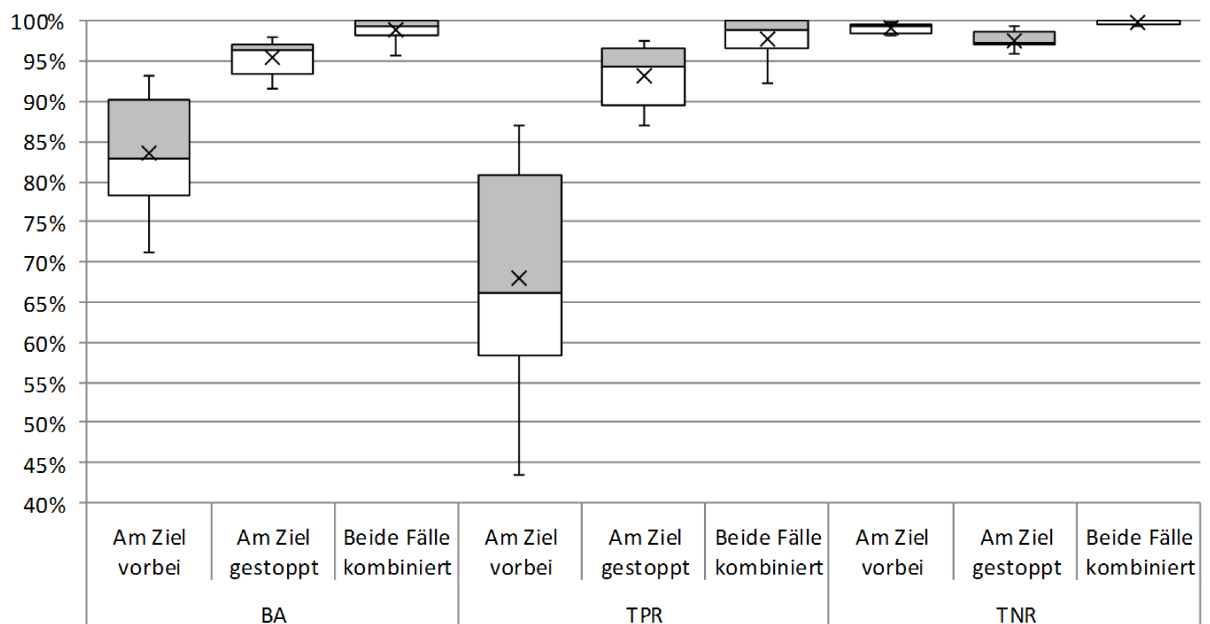
einem Stoppen etwas größer als bei einem Vorbeigehen. Der Signalverlauf im okzipitalen Bereich (Elektrode  $O_z$ ) ist invertiert zu dem Verlauf der Signale im frontalen Bereich. Ein Stoppen des Cursors an der Zielposition lässt sich über die Verarbeitung der Signale im zentralen Bereich erreichen, da der Verlauf in beiden Fällen identisch ist. Lediglich anhand des geringfügig unterschiedlichen Signalverlaufs, im frontalen und okzipitalen Bereich des Gehirns, kann auf ein Überschreiten der Zielposition geschlossen werden.

Anhand der Signalverläufe bei einer aktiven Steuerung konnten zwei Gruppen von Probanden festgestellt werden. Ein Teil der Probanden zeigte die gleichen Verläufe, wie bei der zuvor beschriebenen passiven Steuerung. Bei dem anderen Teil folgte auf den positiven Peak im zentralen und parietalen Bereich (Elektroden  $CP_z$  und  $P_z$ ) ein langsames Abflachen der Signale. Der Stopp an der Zielposition zum Zeitpunkt 1 s bewirkte im frontalen und okzipitalen Bereich einen negativen bzw. positiven Peak. Stoppt der Cursor nicht an der Zielposition, tritt diese Veränderung erst am rechten Bildschirmrand auf (2-2,5 s). Auch bei diesen Probanden lässt sich ein Stoppen des Cursors über die Verarbeitung der Signale im zentralen Bereich realisieren, da die Signalverläufe in beiden Fällen identisch sind. Der unterschiedliche Signalverlauf im frontalen und okzipitalen Bereich des Gehirns ermöglicht die Feststellung einer Überschreitung des Zieles.

Die Abbildung 6.9 zeigt die Verteilungen der Klassifikationsergebnisse über alle Probanden. Die ausführlichen Ergebnisse befinden sich im Anhang in den Tabellen D.2 bis D.5. Der Klassifikator FGMDRM lieferte immer bessere Ergebnisse als der Klassifikator MDRM. Daher wird an dieser Stelle nicht auf die Ergebnisse des MDRM-Klassifikators eingegangen. Zu sehen sind die Ergebnisse der Klassifikation eines Stopps am Ziel, eines Überschreitens des Zieles und der Kombination beider Fälle. Sowohl bei der passiven als auch bei der aktiven Steuerung ist die Spezifität in allen Fällen besonders hoch. Die Sensitivität zeigt, dass bei beiden Steuerungen ein Stoppen am Ziel häufiger detektiert wird als ein Überschreiten des Zieles. Eine Ursache besteht in dem ungleichen Verhältnis der Trainingsdaten und einer Überanpassung an die Klasse „Am Ziel gestoppt“. Weiterhin tritt bei einem Stopp ein zusätzlicher Peak im frontalen und okzipitalen Bereich



(a) Passive Steuerung



(b) Aktive Steuerung

Abbildung 6.9.: Vergleich der Klassifikationsergebnisse bei einer passiven (a) und aktiven (b) Steuerung anhand von ereigniskorrelierten Potenzialen. Den Verteilungen liegen die Ergebnisse aller Probanden zugrunde.

des Gehirns auf, der eine zuverlässigere Detektion ermöglicht. Im Falle der Kombination beider Fälle, sind alle drei Gütekriterien bei der aktiven Steuerung am höchsten, da der Signal-Rausch-Abstand höher ist als bei der passiven Steuerung. Es kommt somit zu weniger Verwechslungen zwischen der Klasse „Ruhephase“ und den beiden anderen Klassen. Die an MS erkrankte Probandin (im Anhang als Proband 9 aufgeführt) erzielte die beste Leistung.

Das in diesem Abschnitt beschriebene ERP-BCI ermöglicht die Detektion der Zielpositionen und die Feststellung von Zielabweichungen bei einer Roboterarmsteuerung. Die Ergebnisse der Kalibrierung haben gezeigt, dass ein Stopp in beiden Fällen sehr zuverlässig bewirkt werden kann. Daher wurde bei der Vergleichsstudie der Stoppmodalitäten (Abschnitt 5.4) das passive ERP-BCI getestet. Der Versuch zeigte, dass die Fehlalarmrate dieser Stoppmodalität sehr hoch ist. Für die Mehrheit der Probanden war ein zuverlässiges Stoppen an der Zielposition nicht möglich, da der Stopp häufig bereits vor dem Ziel erfolgte.



## Kapitel 7.

# Zusammenfassung und Ausblick

### 7.1. Zusammenfassung

Es gibt verschiedene Arten von Mensch-Maschine-Schnittstellen, die es Menschen mit Behinderungen ermöglichen, einen Teil ihrer Autonomie zurück zu erlangen, um so ihre Lebensqualität zu verbessern. Mit Hilfe eines BCIs können Menschen mit sehr begrenzten Bewegungsmöglichkeiten ein Assistenzsystem bedienen und zur Ausführung von autonomen Operationen veranlassen. Das Greifen von Objekten erfolgt dabei über einen integrierten Roboterarm. Im Falle eines Systemfehlers muss der Nutzer jedoch korrigierend eingreifen und den Roboterarm direkt steuern können.

Innerhalb dieser Arbeit wurde eine direkte Roboterarmsteuerung über ein hybrides BCI implementiert und evaluiert. Verschiedene BCI-Ansätze, wie sensomotorische Rhythmen, Alphawellen, Augenartefakte, ereigniskorrelierte und visuell evozierte Potentiale, wurden so miteinander kombiniert und ausgelegt, dass es der Zielgruppe möglich ist, den Greifer eines Roboterarmes in jede Pose zu bringen sowie ein Öffnen und Schließen des Greifers zu bewirken.

Zur Steuerung des Roboterarmes wurde das sBCI-System aus Kapitel 3 verwendet. Dieses System besteht auf der Hardware-Seite aus einem Helm zur Aufnahme der Gehirnströme und einem visuellen Stimulator zur Evokation von ereigniskorrelierten und

visuellen Potenzialen. Mit diesem Gerät kann der Nutzer seinen Blick direkt auf den Roboterarm richten und ist nicht auf eine grafische Benutzerschnittstelle angewiesen. Ein SSVEP-BCI und ERD/ERS-BCI bilden die Software-Komponenten des sBCI-Systems. Das sBCI-System wurde in Kapitel 3 beschrieben und im Rahmen einer Studie getestet.

Zu Beginn der Studie trainierten die Probanden in mehreren Sitzungen die Bewegungsvorstellung der linken und rechten Hand und die der beiden Füße. Zwar konnte sich die Mehrheit der Probanden über drei Sitzungen verbessern, jedoch waren nur wenige Probanden in der Lage, sich alle drei Bewegungen so vorzustellen, dass sie vom System erkannt wurden. Beim größten Teil der Probanden wurde eine Bewegung sehr gut und eine weitere Bewegung nur eingeschränkt erkannt.

Nach dem Training setzten die Probanden die Bewegungsvorstellungen zur Auswahl von Haushaltsgeräten ein. Mit Ausnahme eines Probanden konnten alle Teilnehmer der Studie die Geräte auswählen. Die Steuerung der ausgewählten Geräte erfolgte über das SSVEP-BCI. Hier konnten alle Probanden das SSVEP-BCI nutzen, jedoch lagen die Genauigkeiten und ITR unterhalb der Werte, die der Literatur zu entnehmen sind.

Eine Optimierung des SSVEP-BCIs, hinsichtlich des verwendeten Algorithmus und des verwendeten Stimulators, wurde in Kapitel 4 präsentiert. Das SSVEP-BCI kann sowohl frequenz- als auch phasenbasiert operieren. Beim frequenzbasierten Ansatz blinken alle LEDs mit einer unterschiedlichen Frequenz. Dagegen blinken beim phasenbasierten Ansatz alle LEDs mit der gleichen Frequenz, jedoch phasenverschoben. Zusätzlich wurde in dem Kapitel das P300-BCI beschrieben, das synchron operiert und nicht wie das SSVEP-BCI asynchron. Es benötigt mehrere Wiederholungen einer Sequenz, bevor es eine Klassifikation ausgeben kann. In einer Sequenz leuchten die LEDs, wie die Elemente einer P300-Matrix, zeilen- und spaltenweise auf. Alternativ können die LEDs auch einzeln aufleuchten.

Im Rahmen einer Studie wurden die Paradigmen getestet und hinsichtlich ihrer Genauigkeit und ITR verglichen. Unter Verwendung der LEDs des sBCI-Helmes wurden



eine Verbesserung der mittleren Genauigkeit von 87,27 auf 98,19 % und der mittleren ITR von 15,99 auf 38,04 bits/min erreicht. Vor allem die Betrachtung von zusätzlichen Frequenzen, im Bereich um die Stimulationsfrequenzen, führte zu stabileren und somit besseren Ergebnissen. Weiterhin ließen sich mit kalibrierten Frequenzen bessere Ergebnisse erzielen als mit einem festen Frequenzsatz. Auch die räumliche Filterung nach der MCC-Methode, anstelle der MEC-Methode, führte zu höheren Genauigkeiten. Die Genauigkeit und ITR des phasenbasierten Ansatzes ist geringer als die des frequenzbasierten Ansatzes. Mit den größeren LEDs des optimierten Stimulators konnte im Durchschnitt eine Erhöhung der ITR um ca. 10 bits/min erzielt werden. Die Genauigkeit des P300-BCIs ist genauso hoch wie beim frequenzbasierten SSVEP-BCI. Hingegen ist die ITR nur ungefähr halb so groß.

Mit dem entwickelten SSVEP-BCI und P300-BCI stehen dem Nutzer nur wenige diskrete Kommandos zur Steuerung des Roboters zur Verfügung. Um alle Freiheitsgrade des Roboters steuern zu können, wurde daher ein Zustandsautomat entwickelt. Mit diesem kann der Nutzer zwischen drei Achsen (x, y und z) wechseln, eine Rotations- oder Translationsbewegung vorgeben, die Schrittweite verändern, ein Inkrementieren oder Dekrementieren des gewählten Freiheitsgrades vornehmen und den Greifer öffnen oder schließen. Ebenfalls ist es möglich, einen Wechsel des Roboter-Koordinatensystems zwischen Basis- und Greiferkoordinaten durchzuführen. Da die Stimulation über die LEDs des sBCI-Helms mit der Zeit belastigend und ermüdend auf den Nutzer wirkt, lässt sich diese ausschalten und über das ERD/ERS-BCI einschalten. In Kapitel 4 wurden zwei Zustandsautomaten beschrieben und verglichen. Der 1-Tupel Zustandsautomat nutzt immer ein Kommando zum Umschalten zwischen den Steuerungsgruppen. Hingegen nutzt der 2-Tupel Zustandsautomat eine Sequenz von zwei Kommandos. Die Steuerung innerhalb der Gruppe ist bei beiden Varianten identisch. In den Tests erzielten die Probanden mit dem 2-Tupel Zustandsautomaten die schnellsten Umschaltvorgänge.

Unter Verwendung des frequenzbasierten SSVEP-BCIs und des 2-Tupel Zustandsautomaten, wurde die schrittweise Steuerung des Roboterarmes LWA 3 und des Grei-

fers PG70 des Unternehmens Schunk getestet. Die Regelung des Roboters erfolgte über ein in ROS implementiertes System. Alle Teilnehmer dieser Studie konnten mit dem hybriden BCI eine Pick-and-Place-Aufgabe lösen. Die Steuerung wurde unter objektiven und subjektiven Kriterien bewertet.

Der Nachteil der schrittweisen Steuerung besteht darin, dass nur ein begrenzter Satz an Schrittweiten verwendet werden kann und dieser der Aufgabe entsprechend gewählt werden muss. Außerdem muss der Nutzer sehr viele Steuerkommandos erzeugen und wird somit stark beansprucht. Um diese Nachteile zu beseitigen, wurde die schrittweise Steuerung zu einer geschwindigkeitsbasierten Steuerung erweitert und in Kapitel 5 beschrieben. Anstelle eines diskreten Schritts führt der Roboterarm die Bewegung solange aus, bis entweder eine andere Bewegung vorgegeben oder ein Stopp-Kommando gesendet wird.

Der Stopp wird mit Hilfe des Augenartefakt-HMIs und des Alphawellen-BCIs erreicht. Das Augenartefakt-HMI nutzt die Augenartefakte aus, die beim Schließen der Augen entstehen. Beim Alphawellen-BCI wird der Anstieg der Leistung im Alphafrequenzbereich detektiert, sobald der Mensch die Augen geschlossen hält.

Im Rahmen einer Studie wurden die Stoppmodalitäten miteinander verglichen. Zusätzlich zu den beiden genannten Systemen wurden das SSVEP-BCI aus Kapitel 4 und das ERP-BCI aus Kapitel 6 getestet. Die Studie hat gezeigt, dass das Alphawellen-BCI am zuverlässigsten und das Augenartefakt-HMI am schnellsten und genauesten für einen Stopp sorgt. Weiterhin lieferte die Studie darüber Aufschluss, welche Geschwindigkeiten am geeignetsten für eine BCI-basierte Roboterarmsteuerung sind.

Unter Verwendung des frequenzbasierten SSVEP-BCIs als Umschalt- und Steuermodalität und dem Alphawellen-BCI und Augenartefakt-HMI als Stoppmodalitäten, wurde die geschwindigkeitsbasierte Steuerung des Roboterarmes getestet. Die Aufgabe war identisch mit der Pick-and-Place-Aufgabe der schrittweisen Steuerung. Alle Probanden waren in der Lage, die gestellte Aufgabe zu lösen. Die Steuerung wurde unter

objektiven und subjektiven Kriterien bewertet. Ein Vergleich der beiden Steuerungen hat gezeigt, dass mit der geschwindigkeitsbasierten Steuerung die Aufgabe schneller zu lösen ist, weniger Kommandos benötigt werden und der Nutzer weniger beansprucht wird.

Die Studien haben gezeigt, dass bei einer BCI-basierten Roboterarmsteuerung Fehler auftreten können. Im sechsten Kapitel wurde untersucht, mit welchen Wahrscheinlichkeiten sich Fehler bei der Navigation in einem Zustandsautomaten detektieren lassen. Hierfür wurde das ErrP-BCI entwickelt, welches Fehlerpotenziale im EEG erkennt, die auftreten, sobald der Mensch einen Fehler wahrnimmt. Anhand der Wahrscheinlichkeiten ließ sich ermitteln, ab welchen Genauigkeiten es zu einer Verbesserung kommt, wenn die Erkennung von Fehlerpotentialen berücksichtigt wird. Die Ergebnisse haben gezeigt, dass der Einsatz einer Fehlerkorrektur lediglich bei dem ERD/ERS-BCI empfehlenswert ist, nicht jedoch bei den exogenen BCIs basierend auf SSVEPs und P300-Potenzialen.

Abschließend wurde untersucht, ob ereigniskorrelierte Potenziale auftreten, sobald der Roboterarm seine Zielposition erreicht hat, und, ob Fehlerpotenziale auftreten, falls der Roboter die Zielposition überschreitet. Sowohl bei einer aktiven Steuerung, in der der Mensch aktiv ein Kommando zum Stoppen senden muss als auch bei einer passiven Steuerung, in der der Roboterarm lediglich beobachtet wird, ist ein Erreichen und ein Überschreiten der Zielposition feststellbar. Bei einer aktiven Steuerung treten die Potenziale am stärksten auf. Das in Kapitel 6 beschriebene ERP-BCI ermöglicht die Detektion der Potenziale und wurde in Kapitel 5 als Stopppmodalität getestet.

## 7.2. Ausblick

Die Genauigkeit und Geschwindigkeit, der in dieser Arbeit entwickelten Steuerung, hängt maßgeblich von der Erkennung von SSVEPs ab. Zukünftige Arbeiten könnten die Im-

plementierung weiterer Algorithmen zum Ziel haben, die eine im Vergleich zu den bestehenden Algorithmen bessere Detektion ermöglichen.

Auf der Hardware-Seite ließe sich der sBCI-Helm optimieren. Anstelle der gelbasierten Elektroden könnte der Helm mit wasserbasierten oder trockenen Elektroden ausgestattet werden. Dies hätte eine Verringerung des Aufwandes für das Präparieren und die Reinigung des Helmes zur Folge. In dieser Arbeit wurde bereits festgestellt, dass größere LEDs zu besseren Ergebnissen führen. In zukünftigen Arbeiten könnte bestimmt werden, welche Größe und welche Position der LEDs optimal sind.

Durch die Hinzunahme weiterer LEDs würde der Anwender über mehr Kommandos verfügen, wodurch sich die Umschaltvorgänge minimieren ließen. Es müsste ermittelt werden, wie viele zusätzliche LEDs sich integrieren lassen, ohne, dass dies eine negative Auswirkung auf die Klassifikationsgenauigkeit besitzt.

Weiterhin könnte der sBCI-Helm um ein Head-Mounted Display (HMD) erweitert werden. Über dieses Display könnte der Nutzer eine zusätzliche visuelle Rückmeldung erhalten. Diese Art der Rückmeldung wird derzeit nicht vom System verwendet und wurde während der Experimente von keinem Probanden als notwendig erachtet. Eine rein akustische Rückmeldung wurde als ausreichend bewertet.

Das Steuerungskonzept ließe sich im Hinblick auf eine Änderung der Schrittweite bzw. Geschwindigkeit verbessern. Für die in dieser Arbeit getestete Anwendung waren die drei vorgegebenen Abstufungen ausreichend. Sind jedoch feinere Abstufungen notwendig, so sollte es möglich sein, die vorgegebenen Werte in zwei Richtungen auswählen zu können.

Alternativ zu den Konzepten dieser Arbeit, könnte der Roboterarm eine kontinuierliche Bewegung ausführen, solange der Nutzer seine Konzentration auf eine LED richtet. Das Problem bestünde in der gleichzeitigen Konzentration auf eine LED und den Roboter. Die LEDs des sBCI-Helms befinden sich im peripheren Sichtfeld des Nutzers und somit nicht unbedingt auf der Sichtlinie zum Roboter. Zur Umsetzung dieser Steuerung müssten sich daher die LEDs an dem Greifer des Roboters befinden. Zu große Distanzen

zu den LEDs und die auftretenden Verdeckungen der LEDs stellen die Hauptprobleme weiterer Arbeiten dar.

Ebenfalls ließe sich eine kontinuierliche Bewegung über Bewegungsvorstellungen realisieren. Ein reines endogenes BCI käme ohne eine externe Stimulation aus, was zu einer Verbesserung der Nutzerfreundlichkeit führen würde. Nicht jeder Mensch ist in der Lage, sich Bewegungen so vorzustellen, dass sie vom System erkannt werden. In zukünftigen Arbeiten müsste entweder der Anwenderkreis eingegrenzt oder das Training und die Detektion von Bewegungsvorstellungen verbessert werden. Bei zu geringen Genauigkeiten kann die Verwendung von Fehlerpotenzialen eine Verbesserung bewirken.

Bei der geschwindigkeitsbasierten Steuerung erfolgt das Stoppen des Roboterarmes über ein Schließen und ein Geschlossenhalten der Augen. Detektiert wird dies über die Analyse des EEGs, welches über die Elektroden des Helmes aufgenommen wird. EOG-Elektroden und ein Eye-Tracker stellen zusätzliche Sensoren dar, um ein Schließen der Augen zu erkennen. Durch die Verwendung zusätzlicher Sensoren ließe sich die Sicherheit verbessern.

Auch das SSVEP-BCI und das P300-BCI könnten von EOG-Elektroden und einem Eye-Tracker profitieren. Die Kombination der Blickrichtung und der Aufmerksamkeitsverschiebung auf den Zielstimulus könnte zu einer höheren Genauigkeit und Kommunikationsgeschwindigkeit führen. Hierbei ist jedoch zu beachten, dass die Zielgruppe in diesem Fall über eine willentliche Bewegungsfähigkeit der Augen verfügen muss. Eine reine BCI-basierte Steuerung besitzt diesen Nachteil nicht und ermöglicht somit auch vollständig gelähmten Menschen dessen Verwendung.

Mit Hilfe von Kameras und Laserscannern lassen sich Kollisionen rechtzeitig erkennen und vermeiden, was ebenfalls zu einer Verbesserung der Sicherheit führen würde.



## Literaturverzeichnis

- [1] AFTANAS, L. I. ; GOLOCHEIKINE, S. A.: Human anterior and frontal midline theta and lower alpha reflect emotionally positive state and internalized attention: high-resolution EEG investigation of meditation. In: *Neuroscience Letters* 310 (2001), Nr. 1, S. 57–60
- [2] ALLISON, Brendan ; LÜTH, Thorsten ; VALBUENA, Diana ; TEYMOURIAN, Amir ; VOLOSYAK, Ivan ; GRÄSER, Axel: BCI Demographics: How Many (and What Kinds of) People Can Use an SSVEP BCI? In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 18 (2010), Nr. 2, S. 107–116
- [3] ALLISON, Brendan Z. ; BRUNNER, Clemens ; ALTSTÄTTER, Christof ; WAGNER, Isabella C. ; GRISSMANN, Sebastian ; NEUPER, Christa: A hybrid ERD/SSVEP BCI for continuous simultaneous two dimensional cursor control. In: *Journal of Neuroscience Methods* 209 (2012), Nr. 2, S. 299–307
- [4] ALLISON, Brendan Z. ; MCFARLAND, Dennis J. ; SCHALK, Gerwin ; ZHENG, Shi D. ; JACKSON, Melody M. ; WOLPAW, Jonathan R.: Towards an independent brain–computer interface using steady state visual evoked potentials. In: *Clinical Neurophysiology* 119 (2008), Nr. 2, S. 399–408
- [5] ALLISON, Brendan Z. ; WOLPAW, Elizabeth W. ; WOLPAW, Jonathan R.: Brain–computer interface systems: progress and prospects. In: *Expert Review of Medical Devices* 4 (2007), Nr. 4, S. 463–474

- [6] ALSHARIF, Shiva ; KUZMICHEVA, Olena ; GRÄSER, Axel: Gaze Gesture-Based Human Robot Interface. In: *Technische Unterstützungssysteme, die die Menschen wirklich wollen* (2016), S. 339–348
- [7] ARSIGNY, Vincent ; FILLARD, Pierre ; PENNEC, Xavier ; AYACHE, Nicholas: Geometric Means in a Novel Vector Space Structure on Symmetric Positive-Definite Matrices. In: *SIAM Journal on Matrix Analysis and Applications* 29 (2007), Nr. 1, S. 328–347
- [8] ARTEMIADIS, Panagiotis K. ; KYRIAKOPOULOS, Kostas J.: EMG-Based Control of a Robot Arm Using Low-Dimensional Embeddings. In: *IEEE Transactions on Robotics* 26 (2010), Nr. 2, S. 393–398
- [9] BAILLET, Sylvain ; MOSHER, John C. ; LEAHY, Richard M.: Electromagnetic Brain Mapping. In: *IEEE Signal Processing Magazine* 18 (2001), Nr. 6, S. 14–30
- [10] BARACHANT, Alexandre ; BONNET, Stéphane ; CONGEDO, Marco ; JUTTEN, Christian: Riemannian Geometry Applied to BCI Classification. In: *Latent Variable Analysis and Signal Separation*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2010, S. 629–636
- [11] BARACHANT, Alexandre ; BONNET, Stéphane ; CONGEDO, Marco ; JUTTEN, Christian: Multiclass Brain–Computer Interface Classification by Riemannian Geometry. In: *IEEE Transactions on Biomedical Engineering* 59 (2012), Nr. 4, S. 920–928
- [12] BARACHANT, Alexandre ; BONNET, Stéphane ; CONGEDO, Marco ; JUTTEN, Christian: Classification of covariance matrices using a Riemannian-based kernel for BCI applications. In: *Neurocomputing* 112 (2013), S. 172–178
- [13] BARACHANT, Alexandre ; CONGEDO, Marco: A Plug&Play P300 BCI Using Information Geometry. In: *CoRR* abs/1409.0107 (2014), S. 1–9



- [14] BAREA, Rafael ; BOQUETE, Luciano ; MAZO, Manuel ; LÓPEZ, Elena: System for Assisted Mobility Using Eye Movements Based on Electrooculography. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 10 (2002), Nr. 4, S. 209–218
- [15] BASHASHATI, Ali ; FATOURECHI, Mehrdad ; WARD, Rabab K. ; BIRCH, Gary E.: A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. In: *Journal of Neural Engineering* 4 (2007), Nr. 2, S. R32–R57
- [16] BEESON, Patrick ; AMES, Barrett: TRAC-IK: An Open-Source Library for Improved Solving of Generic Inverse Kinematics. In: *2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids)* IEEE, 2015, S. 928–935
- [17] BERGER, Hans: Über das Elektrenkephalogramm des Menschen. In: *Archiv für Psychiatrie und Nervenkrankheiten* 87 (1929), Nr. 1, S. 527–570
- [18] BHATTACHARYYA, Saugat ; KONAR, Amit ; TIBAREWALA, D. N.: A differential evolution based energy trajectory planner for artificial limb control using motor imagery EEG signal. In: *Biomedical Signal Processing and Control* 11 (2014), S. 107–113
- [19] BHATTACHARYYA, Saugat ; KONAR, Amit ; TIBAREWALA, D. N.: Motor imagery, P300 and error-related EEG-based robot arm movement control for rehabilitation purpose. In: *Medical & Biological Engineering & Computing* 52 (2014), Nr. 12, S. 1007–1017
- [20] BISHOP, Christopher M.: The Multi-layer Perceptron. In: *Neural Networks for Pattern Recognition*. Oxford Clarendon Press, 1995, Kapitel 4, S. 116–163
- [21] BLANKERTZ, Benjamin ; DORNHEGE, Guido ; KRAULEDAT, Matthias ; MÜLLER, Klaus-Robert ; CURIO, Gabriel: The non-invasive Berlin Brain–Computer

- Interface: Fast acquisition of effective performance in untrained subjects. In: *NeuroImage* 37 (2007), Nr. 2, S. 539–550
- [22] BLANKERTZ, Benjamin ; KRAULEDAT, Matthias ; DORNHEGE, Guido ; WILLIAMSON, John ; MURRAY-SMITH, Roderick ; MÜLLER, Klaus-Robert: A Note on Brain Actuated Spelling with the Berlin Brain-Computer Interface. In: *Universal Access in Human-Computer Interaction. Ambient Interaction*. Springer, 2007, S. 759–768
- [23] BLANKERTZ, Benjamin ; LEMM, Steven ; TREDER, Matthias ; HAUFE, Stefan ; MÜLLER, Klaus-Robert: Single-trial analysis and classification of ERP components – A tutorial. In: *NeuroImage* 56 (2011), Nr. 2, S. 814–825
- [24] BLANKERTZ, Benjamin ; LOSCH, Florian ; KRAULEDAT, Matthias ; DORNHEGE, Guido ; CURIO, Gabriel ; MÜLLER, Klaus-Robert: The Berlin Brain–Computer Interface: Accurate Performance From First-Session in BCI-Naïve Subjects. In: *IEEE Transactions on Biomedical Engineering* 55 (2008), Nr. 10, S. 2452–2462
- [25] BOLAGH, Samaneh Nasiri G. ; SHAMSOLLAHI, Mohammad B. ; JUTTEN, Christian ; CONGEDO, Marco: Unsupervised Cross-Subject BCI Learning and Classification using Riemannian Geometry. In: *24th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2016)* European Neural Network Society, 2016, S. 307–312
- [26] BROUWER, Anne-Marie ; VAN ERP, Jan B. F.: A tactile P300 brain-computer interface. In: *Frontiers in Neuroscience* 4 (2010), S. 1–11
- [27] BRUNNER, Clemens ; ALLISON, Brendan Z. ; KRUSIENSKI, Dean J. ; KAISER, Vera ; MÜLLER-PUTZ, Gernot R. ; PFURTSCHELLER, Gert ; NEUPER, Christa: Improved signal processing approaches in an offline simulation of a hybrid brain–computer interface. In: *Journal of Neuroscience Methods* 188 (2010), Nr. 1, S. 165–173

- [28] BRUNNER, P. ; JOSHI, S. ; BRISKIN, S. ; WOLPAW, J. R. ; BISCHOF, H. ; SCHALK, G.: Does the ‘P300’ speller depend on eye gaze? In: *Journal of Neural Engineering* 7 (2010), Nr. 5, S. 1–9
- [29] BURGESS, Christopher J. C.: A Tutorial on Support Vector Machines for Pattern Recognition. In: *Data Mining and Knowledge Discovery* 2 (1998), Nr. 2, S. 121–167
- [30] CHAMBAYIL, Brijil ; SINGLA, Rajesh ; JHA, Rameshwar: Virtual Keyboard BCI using Eye blinks in EEG. In: *2010 IEEE 6th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)* IEEE, 2010, S. 466–470
- [31] CHAVARRIAGA, Ricardo ; DEL R. MILLÁN, José: Learning From EEG Error-Related Potentials in Noninvasive Brain-Computer Interfaces. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 18 (2010), Nr. 4, S. 381–388
- [32] CHAVARRIAGA, Ricardo ; SOBOLEWSKI, Aleksander ; DEL R. MILLÁN, José: Errare machinale est: the use of error-related potentials in brain-machine interfaces. In: *Frontiers in Neuroscience* 8 (2014), S. 1–13
- [33] CHENG, Ming ; GAO, Xiaorong ; GAO, Shangkai ; XU, Dingfeng: Design and Implementation of a Brain-Computer Interface With High Transfer Rates. In: *IEEE Transactions on Biomedical Engineering* 49 (2002), Nr. 10, S. 1181–1186
- [34] CHIEH, Thum C. ; MUSTAFA, Mohd. M. ; HUSSAIN, Aini ; HENDI, Seyed F. ; MAJLIS, Burhanuddin Y.: Development of Vehicle Driver Drowsiness Detection System Using Electrooculogram (EOG). In: *CCSP 2005. 1st International Conference on Computers, Communications, & Signal Processing with Special Track on Biomedical Engineering*. IEEE, 2005, S. 165–168

- [35] CHITTA, Sachin ; SUCAN, Ioan ; COUSINS, Steve: MoveIt! In: *IEEE Robotics & Automation Magazine* 19 (2012), Nr. 1, S. 18–19
- [36] COMBAZ, Adrien ; CHUMERIN, Nikolay ; MANYAKOV, Nikolay V. ; ROBBEN, Arne ; SUYKENS, Johan A. K. ; VAN HULLE, Marc M.: Towards the detection of error-related potentials and its integration in the context of a P300 speller brain–computer interface. In: *Neurocomputing* 80 (2012), S. 73–82
- [37] CROFT, Rodney J. ; BARRY, Robert J.: Removal of ocular artifact from the EEG: a review. In: *Neurophysiologie Clinique/Clinical Neurophysiology* 30 (2000), Nr. 1, S. 5–19
- [38] CURRAN, Eleanor A. ; STOKES, Maria J.: Learning to control brain activity: A review of the production and control of EEG components for driving brain–computer interface (BCI) systems. In: *Brain and cognition* 51 (2003), Nr. 3, S. 326–336
- [39] DORNHEGE, Guido ; KRAULEDAT, Matthias ; MÜLLER, Klaus-Robert ; BLANKERTZ, Benjamin: General Signal Processing and Machine Learning Tools for BCI Analysis. In: *Toward Brain-Computer Interfacing*. The MIT Press, 2007, Kapitel 13, S. 207–234
- [40] DRAPER, Norman R. ; SMITH, Harry: Stepwise Regression. In: *Applied Regression Analysis*. 3. John Wiley & Sons, Inc., 1998, Kapitel 15.2, S. 335–339
- [41] DUDA, Richard O. ; HART, Peter E. ; STORK, David G.: Linear Discriminant Functions. In: *Pattern Classification*. 2. John Wiley & Sons, Inc., 2001, Kapitel 5, S. 215–281
- [42] DUDA, Richard O. ; HART, Peter E. ; STORK, David G.: Multiple Discriminant Analysis. In: *Pattern Classification*. 2. John Wiley & Sons, Inc., 2001, Kapitel 3.8.3, S. 121–124

- [43] DURBIN, James: Efficient estimation of parameters in moving-average models. In: *Biometrika* 46 (1959), Nr. 3/4, S. 306–316
- [44] FALKENSTEIN, Michael ; HOORMANN, Jörg ; CHRIST, Stefan ; HOHNSBEIN, Joachim: ERP components on reaction errors and their functional significance: a tutorial. In: *Biological Psychology* 51 (2000), Nr. 2, S. 87–107
- [45] FARWELL, Lawrence A. ; DONCHIN, Emanuel: Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. In: *Electroencephalography and clinical Neurophysiology* 70 (1988), Nr. 6, S. 510–523
- [46] FATOURECHI, Mehrdad ; BASHASHATI, Ali ; WARD, Rabab K. ; BIRCH, Gary E.: EMG and EOG artifacts in brain computer interface systems: A survey. In: *Clinical Neurophysiology* 118 (2007), Nr. 3, S. 480–494
- [47] FAWCETT, Tom: ROC Graphs: Notes and Practical Considerations for Researchers. In: *Machine Learning* 31 (2004), Nr. 1, S. 1–38
- [48] FAZEL-REZAI, Reza ; ABHARI, Kamyar: A region-based P300 speller for brain-computer interface. In: *Canadian Journal of Electrical and Computer Engineering* 34 (2009), Nr. 3, S. 81–85
- [49] FEHMI, Lester G. ; COLLURA, Thomas: Effects of Electrode Placement Upon EEG Biofeedback Training: The Monopolar-Bipolar Controversy. In: *Journal of Neurotherapy* 11 (2007), Nr. 2, S. 45–63
- [50] FERREZ, Pierre W. ; DEL R. MILLÁN, José: You Are Wrong!—Automatic Detection of Interaction Errors from Brain Waves. In: *Proceedings of the 19th International Joint Conference on Artificial Intelligence, 2005 (IJCAI'05)*, S. 1413–1418
- [51] FERREZ, Pierre W. ; DEL R. MILLÁN, José: Error-Related EEG Potentials Generated During Simulated Brain–Computer Interaction. In: *IEEE Transactions on Biomedical Engineering* 55 (2008), Nr. 3, S. 923–929

- [52] FERREZ, Pierre W. ; DEL R. MILLÁN, José: Simultaneous Real-Time Detection of Motor Imagery and Error-Related Potentials for Improved BCI Accuracy. In: *Proceedings of the 4th International Brain-Computer Interface Workshop and Training Course*, 2008, S. 197–202
- [53] FISHER, Robert S. ; HARDING, Graham ; ERBA, Giuseppe ; BARKLEY, Gregory L. ; WILKINS, Arnold: Photic- and Pattern-induced Seizures: A Review for the Epilepsy Foundation of America Working Group. In: *Epilepsia* 46 (2005), Nr. 9, S. 1426–1441
- [54] FLETCHER, P. T. ; JOSHI, Sarang: Riemannian Geometry for the Statistical Analysis of Diffusion Tensor Data. In: *Signal Processing* 87 (2007), Nr. 2, S. 250–262
- [55] FONSECA, Carlos ; CUNHA, J. P. S. ; MARTINS, R. E. ; FERREIRA, V. M. ; DE SÁ, J. P. M. ; BARBOSA, M. A. ; DA SILVA, A. M.: A Novel Dry Active Electrode for EEG Recording. In: *IEEE Transactions on Biomedical Engineering* 54 (2007), Nr. 1, S. 162–165
- [56] FRIMAN, Ola ; LÜTH, Thorsten ; VOLOSYAK, Ivan ; GRÄSER, Axel: Spelling with Steady-State Visual Evoked Potentials. In: *CNE'07. 3rd International IEEE/EMBS Conference on Neural Engineering* IEEE, 2007, S. 354–357
- [57] FRIMAN, Ola ; VOLOSYAK, Ivan ; GRÄSER, Axel: Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces. In: *IEEE Transactions on Biomedical Engineering* 54 (2007), Nr. 4, S. 742–750
- [58] FUKUNAGA, Keinosuke: Discriminant Analysis. In: *Introduction to Statistical Pattern Recognition*. 2. Academic Press, Inc., 1990, Kapitel 10.2, S. 445–459
- [59] FURDEA, Adrian ; HALDER, Sebastian ; KRUSIENSKI, D. J. ; BROSS, Donald ; NIJBOER, Femke ; BIRBAUMER, Niels ; KÜBLER, Andrea: An auditory oddball

- (P300) spelling system for brain-computer interfaces. In: *Psychophysiology* 46 (2009), Nr. 3, S. 617–625
- [60] GAO, Xiaorong ; XU, Dingfeng ; CHENG, Ming ; GAO, Shangkai: A BCI-Based Environmental Controller for the Motion-Disabled. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11 (2003), Nr. 2, S. 137–140
- [61] GARCÍA, Vicente ; MOLLINEDA, Ramón A. ; SÁNCHEZ, José S.: Index of Balanced Accuracy: A Performance Measure for Skewed Class Distributions. In: *Iberian Conference on Pattern Recognition and Image Analysis* Springer, 2009, S. 441–448
- [62] GOLDMAN, Robin I. ; STERN, John M. ; ENGEL JR, Jerome ; COHEN, Mark S.: Simultaneous EEG and fMRI of the alpha rhythm. In: *Neuroreport* 13 (2002), Nr. 18, S. 2487–2492
- [63] GRÄSER, Axel ; HEYER, Torsten ; FOTOOHI, Leila ; LANGE, Uwe ; KAMPE, Henning ; ENJARINI, Bashar ; HEYER, Stefan ; FRAGKOPOULOS, Christos ; RISTIĆ-DURRANT, Danijela: A Supportive FRIEND at Work: Robotic Workplace Assistance for the Disabled. In: *IEEE Robotics & Automation Magazine* 20 (2013), Nr. 4, S. 148–159
- [64] GRAY, M. ; KEMP, A. H. ; SILBERSTEIN, R. B. ; NATHAN, P. J.: Cortical neurophysiology of anticipatory anxiety: an investigation utilizing steady state probe topography (SSPT). In: *NeuroImage* 20 (2003), Nr. 2, S. 975–986
- [65] GUGER, Christoph ; DABAN, Shahab ; SELLERS, Eric ; HOLZNER, Clemens ; KRAUSZ, Gunther ; CARABALONA, Roberta ; GRAMATICA, Furio ; EDLINGER, Guenter: How many people are able to control a P300-based brain-computer interface (BCI)? In: *Neuroscience Letters* 462 (2009), Nr. 1, S. 94–98

- [66] HAJCAK, Greg ; MOSER, Jason S. ; YEUNG, Nick ; SIMONS, Robert F.: On the ERN and the significance of errors. In: *Psychophysiology* 42 (2005), Nr. 2, S. 151–160
- [67] HANSLMAYR, Simon ; SAUSENG, Paul ; DOPPELMAYR, Michael ; SCHABUS, Manuel ; KLIMESCH, Wolfgang: Increasing Individual Upper Alpha Power by Neurofeedback Improves Cognitive Performance in Human Subjects. In: *Applied Psychophysiology and Biofeedback* 30 (2005), Nr. 1, S. 1–10
- [68] HART, Sandra G. ; STAVELAND, Lowell E.: Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research. In: *Advances in Psychology* 52 (1988), S. 139–183
- [69] HASELSTEINER, Ernst ; PFURTSCHELLER, Gert: Using Time-Dependent Neural Networks for EEG Classification. In: *IEEE Transactions on Rehabilitation Engineering* 8 (2000), Nr. 4, S. 457–463
- [70] HERRMANN, Christoph S.: Human EEG responses to 1–100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena. In: *Experimental Brain Research* 137 (2001), Nr. 3, S. 346–353
- [71] HJORTH, Bo: An on-line transformation of EEG scalp potentials into orthogonal source derivations. In: *Electroencephalography and Clinical Neurophysiology* 39 (1975), Nr. 5, S. 526–530
- [72] HORTAL, E. ; PLANELLES, D. ; COSTA, A. ; IÁÑEZ, E. ; ÚBEDA, A. ; AZORÍN, J. M. ; FERNÁNDEZ, E.: SVM-based Brain–Machine Interface for controlling a robot arm through four mental tasks. In: *Neurocomputing* 151 (2015), S. 116–121
- [73] HORTAL, Enrique ; ÚBEDA, Andrés ; IÁÑEZ, Eduardo ; AZORÍN, José M.: Control of a 2 DoF robot using a Brain–Machine Interface. In: *Computer Methods and Programs in Biomedicine* 116 (2014), Nr. 2, S. 169–176



- [74] HOUSE, Brandi ; MALKIN, Jonathan ; BILMES, Jeff: The VoiceBot: A Voice Controlled Robot Arm. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, ACM, 2009 (CHI '09), S. 183–192
- [75] HWANG, Han-Jeong ; KWON, Kiwoon ; IM, Chang-Hwang: Neurofeedback-based motor imagery training for brain–computer interface (BCI). In: *Journal of Neuroscience Methods* 179 (2009), Nr. 1, S. 150–156
- [76] IÁÑEZ, Eduardo ; ÚBEDA, Andrés ; AZORÍN, José M.: Multimodal human-machine interface based on a Brain-Computer Interface and an electrooculography interface. In: *33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* IEEE, 2011, S. 4572–4575
- [77] IÁÑEZ, Eduardo ; ÚBEDA, Andrés ; AZORÍN, José M ; PEREZ-VIDAL, Carlos: Assistive robot application based on an RFID control architecture and a wireless EOG interface. In: *Robotics and Autonomous Systems* 60 (2012), Nr. 8, S. 1069–1077
- [78] INOUE, Shinsuke ; AKIYAMA, Yoko ; IZUMI, Yoshinobu ; NISHIJIMA, Shigehiro: The Development of BCI Using Alpha Waves for Controlling the Robot Arm. In: *IEICE Transactions on Communications* 91 (2008), Nr. 7, S. 2125–2132
- [79] ITURRATE, I. ; ANTELIS, J. M. ; KÜBLER, A. ; MINGUEZ, J.: A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. In: *IEEE Transactions on Robotics* 25 (2009), Nr. 3, S. 614–627
- [80] IWASAKI, Masaki ; KELLINGHAUS, Christoph ; ALEXOPOULOS, Andreas V. ; BURGESS, Richard C. ; KUMAR, Arun N. ; HAN, Yanning H. ; LÜDERS, Hans O. ; LEIGH, R. J.: Effects of eyelid closure, blinks, and eye movements on the electroencephalogram. In: *Clinical Neurophysiology* 116 (2005), Nr. 4, S. 878–885

- [81] JAIN, Anil K. ; DUIN, Robert P. W. ; MAO, Jianchang: Statistical Pattern Recognition: A Review. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22 (2000), Nr. 1, S. 4–37
- [82] JASPER, Herbert H.: The Ten-Twenty Electrode System of the International Federation. In: *Electroencephalography and Clinical Neurophysiology* 10 (1958), S. 371–375
- [83] JEANNEROD, Marc: Neural Simulation of Action: A Unifying Mechanism for Motor Cognition. In: *NeuroImage* 14 (2001), Nr. 1, S. S103–S109
- [84] JEANNEROD, Marc ; FRAK, Victor: Mental imaging of motor activity in humans. In: *Current Opinion in Neurobiology* 9 (1999), Nr. 6, S. 735–739
- [85] JURKIEWICZ, Michael T. ; GAETZ, William C. ; BOSTAN, Andreea C. ; CHEYNE, Douglas: Post-movement beta rebound is generated in motor cortex: Evidence from neuromagnetic recordings. In: *NeuroImage* 32 (2006), Nr. 3, S. 1281–1289
- [86] KALCHER, J. ; FLOTZINGER, D. ; NEUPER, Ch. ; GÖLLY, S. ; PFURTSCHELLER, G.: Graz brain–computer interface II: towards communication between humans and computers based on online classification of three different EEG patterns. In: *Medical and Biological Engineering and Computing* 34 (1996), Nr. 5, S. 382–388
- [87] KALUNGA, Emmanuel K. ; CHEVALLIER, Sylvain ; BARTHÉLEMY, Quentin ; DJOUANI, Karim ; MONACELLI, Eric ; HAMAM, Yskandar: Online SSVEP-based BCI using Riemannian geometry. In: *Neurocomputing* 191 (2016), S. 55–68
- [88] KELLY, Simon P. ; LALOR, Edmund C. ; FINUCANE, Ciarán ; MCDARBY, Gary ; REILLY, Richard B.: Visual Spatial Attention Control in an Independent Brain-Computer Interface. In: *IEEE Transactions on Biomedical Engineering* 52 (2005), Nr. 9, S. 1588–1596

- [89] KOHAVI, Ron: A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence* Bd. 14, Morgan Kaufmann Publishers Inc., 1995 (IJCAI'95 2), S. 1137–1145
- [90] KOPELL, N. ; ERMENTROUT, G. B. ; WHITTINGTON, M. A. ; TRAUB, R. D.: Gamma rhythms and beta rhythms have different synchronization properties. In: *Proceedings of the National Academy of Sciences* 97 (2000), Nr. 4, S. 1867–1872
- [91] KRAULEDAT, Matthias ; TANGERMANN, Michael ; BLANKERTZ, Benjamin ; MÜLLER, Klaus-Robert: Towards Zero Training for Brain-Computer Interfacing. In: *PLOS ONE* 3 (2008), Nr. 8, S. 1–12
- [92] KREPKE, Roman ; BLANKERTZ, Benjamin ; CURIO, Gabriel ; MÜLLER, Klaus-Robert: The Berlin Brain-Computer Interface (BBCI)–towards a new communication channel for online control in gaming applications. In: *Multimedia Tools and Applications* 33 (2007), Nr. 1, S. 73–90
- [93] KRUSIENSKI, Dean J. ; SELLERS, Eric W. ; CABESTAING, François ; BAYOUDH, Sabri ; MCFARLAND, Dennis J. ; VAUGHAN, Theresa M. ; WOLPAW, Jonathan R.: A comparison of classification techniques for the P300 Speller. In: *Journal of Neural Engineering* 3 (2006), Nr. 4, S. 299–305
- [94] KÜBLER, Andrea ; BIRBAUMER, Niels: Brain–computer interfaces and communication in paralysis: Extinction of goal directed thinking in completely paralysed patients? In: *Clinical Neurophysiology* 119 (2008), Nr. 11, S. 2658–2666
- [95] KÜBLER, Andrea ; KOTCHOUBEY, Boris ; KAISER, Jochen ; WOLPAW, Jonathan R. ; BIRBAUMER, Niels: Brain–Computer Communication: Unlocking the Locked In. In: *Psychological Bulletin* 127 (2001), Nr. 3, S. 358–375

- [96] KÜBLER, Andrea ; NIJBOER, Femke ; MELLINGER, Jürgen ; VAUGHAN, Theresa M. ; PAWELZIK, Hannelore ; SCHALK, Gerwin ; MCFARLAND, Dennis J. ; BIRBAUMER, Niels ; WOLPAW, Jonathan R.: Patients with ALS can use sensorimotor rhythms to operate a brain-computer interface. In: *Neurology* 64 (2005), Nr. 10, S. 1775–1777
- [97] KUHTZ-BUSCHBECK, J. P. ; MAHNKOPF, C. ; HOLZKNECHT, C. ; SIEBNER, H. ; ULMER, S. ; JANSEN, O.: Effector-independent representations of simple and complex imagined finger movements: a combined fMRI and TMS study. In: *European Journal of Neuroscience* 18 (2003), Nr. 12, S. 3375–3387
- [98] KUS, Rafal ; VALBUENA, Diana ; ZYGIEREWICZ, Jaroslaw ; MALECHKA, Tatsiana ; GRÄSER, Axel ; DURKA, Piotr: Asynchronous BCI Based on Motor Imagery With Automated Calibration and Neurofeedback Training. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 20 (2012), Nr. 6, S. 823–835
- [99] LALOR, Edmund C. ; KELLY, Simon P. ; FINUCANE, Ciarán ; BURKE, Robert ; SMITH, Ray ; REILLY, Richard B. ; MCDARBY, Gary: Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. In: *EURASIP Journal on Applied Signal Processing* 2005 (2005), S. 3156–3164
- [100] LAWHERN, Vernon ; HAIRSTON, W. D. ; MCDOWELL, Kaleb ; WESTERFIELD, Marissa ; ROBBINS, Kay: Detection and classification of subject-generated artifacts in EEG signals using autoregressive models. In: *Journal of Neuroscience Methods* 208 (2012), Nr. 2, S. 181–189
- [101] LE VAN QUYEN, Michel ; FOUCHER, Jack ; LACHAUX, Jean-Philippe ; RODRIGUEZ, Eugenio ; LUTZ, Antoine ; MARTINERIE, Jacques ; VARELA, Francisco J.: Comparison of Hilbert transform and wavelet methods for the analysis of neuronal synchrony. In: *Journal of Neuroscience Methods* 111 (2001), Nr. 2, S. 83–98

- [102] LEE, Te-Won ; GIROLAMI, Mark ; SEJNOWSKI, Terrence J.: Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Subgaussian and Supergaussian Sources. In: *Neural Computation* 11 (1999), Nr. 2, S. 417–441
- [103] LI, Ting ; HONG, Jun ; ZHANG, Jinhua ; GUO, Feng: Brain-machine interface control of a manipulator using small-world neural network and shared control strategy. In: *Journal of Neuroscience Methods* 224 (2014), S. 26–38
- [104] LI, Yuanqing ; LONG, Jinyi ; YU, Tianyou ; YU, Zhuliang ; WANG, Chuanchu ; ZHANG, Haihong ; GUAN, Cuntai: An EEG-Based BCI System for 2-D Cursor Control by Combining Mu/Beta Rhythm and P300 Potential. In: *IEEE Transactions on Biomedical Engineering* 57 (2010), Nr. 10, S. 2495–2505
- [105] LIKERT, Rensis: A technique for the measurement of attitudes. In: *Archives of Psychology* (1932)
- [106] LIN, Chin-Teng ; LIANG, Sheng-Fu ; CHEN, Yu-Chieh ; HSU, Yung-Chi ; KO, Li-Wei: Driver's Drowsiness Estimation by Combining EEG Signal Analysis and ICA-based Fuzzy Neural Networks. In: *2006 IEEE International Symposium on Circuits and Systems*. IEEE, 2006, S. 2125–2128
- [107] LLERA, A. ; VAN GERVEN, M. A. J. ; GÓMEZ, V. ; JENSEN, O. ; KAPPEN, H. J.: On the use of interaction error potentials for adaptive brain computer interfaces. In: *Neural Networks* 24 (2011), Nr. 10, S. 1120–1127
- [108] LÜTH, Thorsten ; OJDANIĆ, Darko ; FRIMAN, Ola ; PRENZEL, Oliver ; GRÄSER, Axel: Low level control in a semi-autonomous rehabilitation robotic system via a Brain-Computer Interface. In: *2007 IEEE 10th International Conference on Rehabilitation Robotics* IEEE, 2007, S. 721–728
- [109] MAHALANOBIS, Prasanta C.: On the generalized distance in statistics. In: *Proceedings of the National Institute of Sciences* 2 (1936), Nr. 1, S. 49–55

- [110] MALECHKA, Tatsiana: Hybrides Brain-Computer Interface. In: *Optimierung der Signalverarbeitung für ein hybrides Brain-Computer Interface*. Shaker Verlag, 2015, Kapitel 6, S. 77–96
- [111] MALECHKA, Tatsiana: *Optimierung der Signalverarbeitung für ein hybrides Brain-Computer Interface*. Shaker Verlag, 2015
- [112] MALECHKA, Tatsiana: Signalverarbeitung für das SMR-BCI. In: *Optimierung der Signalverarbeitung für ein hybrides Brain-Computer Interface*. Shaker Verlag, 2015, Kapitel 3, S. 33–56
- [113] MALECHKA, Tatsiana ; TETZEL, Tobias ; KREBS, Ulrich ; FEUSER, Diana ; GRÄSER, Axel: sBCI-Headset—Wearable and Modular Device for Hybrid Brain-Computer Interface. In: *Micromachines* 6 (2015), Nr. 3, S. 291–311
- [114] MALMIVUO, Jaakko ; PLONSEY, Robert: Electroencephalography. In: *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, 1995, Kapitel 13, S. 257–264
- [115] MARTINEZ, Pablo ; BAKARDJIAN, Hovagim ; CICHOCKI, Andrzej: Fully Online Multicommand Brain-Computer Interface with Visual Neurofeedback Using SS-VEP Paradigm. In: *Computational Intelligence and Neuroscience* 2007 (2007), S. 1–9
- [116] MASON, S. G. ; BASHASHATI, A. ; FATOURECHI, M. ; NAVARRO, K. F. ; BIRCH, G. E.: A Comprehensive Survey of Brain Interface Technology Designs. In: *Annals of Biomedical Engineering* 35 (2007), Nr. 2, S. 137–169
- [117] MATSUO, Fumisuke ; PETERS, Jon F. ; REILLY, Edward L.: Electrical phenomena associated with movements of the eyelid. In: *Electroencephalography and Clinical Neurophysiology* 38 (1975), Nr. 5, S. 507–511

- [118] MCFARLAND, Dennis J. ; MINER, Laurie A. ; VAUGHAN, Theresa M. ; WOLPAW, Jonathan R.: Mu and Beta Rhythm Topographies During Motor Imagery and Actual Movements. In: *Brain Topography* 12 (2000), Nr. 3, S. 177–186
- [119] MEINICKE, Peter ; KAPER, Matthias ; HOPPE, Florian ; HEUMANN, Manfred ; RITTER, Helge: Improving Transfer Rates in Brain Computer Interfacing: A Case Study. In: *Proceedings of the 15th International Conference on Neural Information Processing Systems*, MIT Press, 2002 (NIPS'02), S. 1131–1138
- [120] MIDDENDORF, Matthew ; McMILLAN, Grant ; CALHOUN, Gloria ; JONES, Keith S.: Brain–Computer Interfaces Based on the Steady-State Visual-Evoked Response. In: *IEEE Transactions on Rehabilitation Engineering* 8 (2000), Nr. 2, S. 211–214
- [121] MILTNER, Wolfgang H. R. ; BRAUN, Christoph H. ; COLES, Michael G. H.: Event-Related Brain Potentials Following Incorrect Feedback in a Time-Estimation Task: Evidence for a “Generic” Neural System for Error Detection. In: *Journal of Cognitive Neuroscience* 9 (1997), Nr. 6, S. 788–798
- [122] MOAKHER, Maher: A Differential Geometric Approach to the Geometric Mean of Symmetric Positive-Definite Matrices. In: *SIAM Journal on Matrix Analysis and Applications* 26 (2005), Nr. 3, S. 735–747
- [123] MOLINA, Gary G. ; ZHU, Danhua ; ABTAHI, Shirin: Phase detection in a visual-evoked-potential based brain computer interface. In: *2010 18th European Signal Processing Conference IEEE*, 2010, S. 949–953
- [124] MÜLLER-PUTZ, Gernot R. ; PFURTSCHELLER, Gert: Control of an Electrical Prosthesis With an SSVEP-Based BCI. In: *IEEE Transactions on Biomedical Engineering* 55 (2008), Nr. 1, S. 361–364

- [125] MÜLLER-PUTZ, Gernot R. ; SCHERER, Reinhold ; BRAUNEIS, Christian ; PFURTSCHELLER, Gert: Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. In: *Journal of Neural Engineering* 2 (2005), Nr. 4, S. 123–130
- [126] NEUPER, C. ; PFURTSCHELLER, G.: Event-related dynamics of cortical rhythms: frequency-specific features and functional correlates. In: *International Journal of Psychophysiology* 43 (2001), Nr. 1, S. 41–58
- [127] NEUPER, Christa ; SCHERER, Reinhold ; REINER, Miriam ; PFURTSCHELLER, Gert: Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG. In: *Cognitive Brain Research* 25 (2005), Nr. 3, S. 668–677
- [128] NICOLAS-ALONSO, Luis F. ; GOMEZ-GIL, Jaime: Brain Computer Interfaces, a Review. In: *Sensors* 12 (2012), Nr. 2, S. 1211–1279
- [129] NIJBOER, Femke ; FURDEA, Adrian ; GUNST, Ingo ; MELLINGER, Jürgen ; MCFARLAND, Dennis J. ; BIRBAUMER, Niels ; KÜBLER, Andrea: An auditory brain–computer interface (BCI). In: *Journal of Neuroscience Methods* 167 (2008), Nr. 1, S. 43–50
- [130] NUNEZ, Paul L. ; SRINIVASAN, Ramesh: Recording Strategies, Reference Issues, and Dipole Localization. In: *Electric Fields of the Brain: The Neurophysics of EEG*. 2. Oxford University Press, 2006, Kapitel 7, S. 275–312
- [131] PALANKAR, Mayur ; DE LAURENTIS, Kathryn J. ; ALQASEMI, Redwan ; VERAS, Eduardo ; DUBEY, Rajiv ; ARBEL, Yael ; DONCHIN, Emanuel: Control of a 9-DoF Wheelchair-Mounted Robotic Arm System Using a P300 Brain Computer Interface: Initial Experiments. In: *2008 IEEE International Conference on Robotics and Biomimetics* IEEE, 2009, S. 348–353



- [132] PASTOR, Maria A. ; ARTIEDA, Julio ; ARBIZU, Javier ; VALENCIA, Miguel ; MAS-DEU, Jose C.: Human Cerebral Activation during Steady-State Visual-Evoked Responses. In: *Journal of Neuroscience* 23 (2003), Nr. 37, S. 11621–11627
- [133] PENG, Hanchuan ; LONG, Fuhui ; DING, Chris: Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 27 (2005), Nr. 8, S. 1226–1238
- [134] PENGHAI, Li ; BAIKUN, Wan: A Study on EEG Alpha Wave-based Brain-Computer Interface Remote Control System. In: *2007 International Conference on Mechatronics and Automation* IEEE, 2007, S. 3179–3184
- [135] PFURTSCHELLER, G.: Functional brain imaging based on ERD/ERS. In: *Vision Research* 41 (2001), Nr. 10–11, S. 1257–1260
- [136] PFURTSCHELLER, G. ; DA SILVA, F. H. L.: Event-related EEG/MEG synchronization and desynchronization: basic principles. In: *Clinical Neurophysiology* 110 (1999), Nr. 11, S. 1842–1857
- [137] PFURTSCHELLER, G. ; NEUPER, C. ; MÜLLER, G. R. ; OBERMAIER, B. ; KRAUSZ, G. ; SCHLÖGL, A. ; SCHERER, R. ; GRAIMANN, B. ; KEINRATH, C. ; SKLIRIS, D. ; WÖRTZ, M. ; SUPP, G. ; SCHRANK, C.: Graz-BCI: State of the Art and Clinical Applications. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11 (2003), Nr. 2, S. 177–180
- [138] PFURTSCHELLER, Gert ; ALLISON, Brendan Z. ; BRUNNER, Clemens ; BAUERNFEIND, Gunther ; SOLIS-ESCALANTE, Teodoro ; SCHERER, Reinhold ; ZANDER, Thorsten O. ; MUELLER-PUTZ, Gernot ; NEUPER, Christa ; BIRBAUMER, Niels: The hybrid BCI. In: *Frontiers in Neuroscience* 4 (2010)

- [139] PFURTSCHELLER, Gert ; GUGER, C. ; MÜLLER, G. ; KRAUSZ, G. ; NEUPER, C.: Brain oscillations control hand orthosis in a tetraplegic. In: *Neuroscience Letters* 292 (2000), Nr. 3, S. 211–214
- [140] PFURTSCHELLER, Gert ; MÜLLER, Gernot R. ; PFURTSCHELLER, Jörg ; GERNER, Hans J. ; RUPP, Rüdiger: ‘Thought’ – control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. In: *Neuroscience Letters* 351 (2003), Nr. 1, S. 33–36
- [141] PFURTSCHELLER, Gert ; NEUPER, Christa: Motor Imagery and Direct Brain–Computer Communication. In: *Proceedings of the IEEE* 89 (2001), Nr. 7, S. 1123–1134
- [142] PHILIPS, Johan ; DEL R. MILLÁN, José ; VANACKER, Gerolf ; LEW, Eileen ; GALÁN, Ferran ; FERREZ, Pierre W. ; VAN BRUSSEL, Hendrik ; NUTTIN, Marnix: Adaptive Shared Control of a Brain-Actuated Simulated Wheelchair. In: *2007 IEEE 10th International Conference on Rehabilitation Robotics* IEEE, 2007, S. 408–414
- [143] PICCIONE, Francesco ; GIORGI, Flavio ; TONIN, Paolo ; PRIFTIS, K. ; GIOVE, S. ; SILVONI, Stefano ; PALMAS, G. ; BEVERINA, F.: P300-based brain computer interface: Reliability and performance in healthy and paralysed participants. In: *Clinical Neurophysiology* 117 (2006), Nr. 3, S. 531–537
- [144] PINEDA, Jaime A.: The functional significance of mu rhythms: Translating “seeing” and “hearing” into “doing”. In: *Brain Research Reviews* 50 (2005), Nr. 1, S. 57–68
- [145] POLICH, John: Updating P300: An integrative theory of P3a and P3b. In: *Clinical Neurophysiology* 118 (2007), Nr. 10, S. 2128–2148

- [146] POLICH, John ; ELLERSON, Patricia C. ; COHEN, Jill: P300, stimulus intensity, modality, and probability. In: *International Journal of Psychophysiology* 23 (1996), Nr. 1–2, S. 55–62
- [147] PREGENZER, Martin ; PFURTSCHELLER, Gert: Frequency Component Selection for an EEG-Based Brain to Computer Interface. In: *IEEE Transactions on Rehabilitation Engineering* 7 (1999), Nr. 4, S. 413–419
- [148] QIAN, Zhiyu ; WANG, Xiao ; LAN, Chenyun ; LI, Weitao: Analysis of Fatigue with 3D TV Based on EEG. In: *2013 1st International Conference on Orange Technologies (ICOT)* IEEE, 2013, S. 306–309
- [149] QIN, Lei ; HE, Bin: A wavelet-based time–frequency analysis approach for classification of motor imagery for brain–computer interface applications. In: *Journal of Neural Engineering* 2 (2005), Nr. 4, S. 65–72
- [150] QUIGLEY, Morgan ; GERKEY, Brian ; CONLEY, Ken ; FAUST, Josh ; FOOTE, Tully ; LEIBS, Jeremy ; BERGER, Eric ; WHEELER, Rob ; NG, Andrew: ROS: an open-source Robot Operating System. In: *ICRA Workshop on Open Source Software* Bd. 3, 2009, S. 5
- [151] RAVDEN, Daran ; POLICH, John: On P300 measurement stability: habituation, intra-trial block variation, and ultradian rhythms. In: *Biological Psychology* 51 (1999), Nr. 1, S. 59–76
- [152] REBSAMEN, Brice ; BURDET, Etienne ; GUAN, Cuntai ; TEO, Chee L. ; ZENG, Qiang ; ANG, Marcelo ; LAUGIER, Christian: Controlling a wheelchair using a BCI with low information transfer rate. In: *2007 IEEE 10th International Conference on Rehabilitation Robotics* IEEE, 2007, S. 1003–1008
- [153] RUDIGKEIT, Nina ; GEBHARD, Marion ; GRÄSER, Axel: Evaluation of Control Modes for Head Motion-based Control with Motion Sensors. In: *2015 IEEE Inter-*

- national Symposium on Medical Measurements and Applications (MeMeA)* IEEE, 2015, S. 135–140
- [154] SALVARIS, Mathew ; SEPULVEDA, Francisco: Visual modifications on the P300 speller BCI paradigm. In: *Journal of Neural Engineering* 6 (2009), Nr. 4, S. 1–8
- [155] SCHALK, Gerwin: Sensor Modalities for Brain-Computer Interfacing. In: *International Conference on Human-Computer Interaction* Springer, 2009, S. 616–622
- [156] SCHALK, Gerwin ; MCFARLAND, Dennis J. ; HINTERBERGER, Thilo ; BIRBAUMER, Niels ; WOLPAW, Jonathan R.: BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. In: *IEEE Transactions on Biomedical Engineering* 51 (2004), Nr. 6, S. 1034–1043
- [157] SCHLÖGL, Alois ; LEE, Felix ; BISCHOF, Horst ; PFURTSCHELLER, Gert: Characterization of four-class motor imagery EEG data for the BCI-competition 2005. In: *Journal of Neural Engineering* 2 (2005), Nr. 4, S. L14–L22
- [158] SCHLÖGL, Alois ; LUGGER, Klaus ; PFURTSCHELLER, Gert: Using adaptive autoregressive parameters for a brain-computer-interface experiment. In: *Engineering in Medicine and Biology Society, 1997. Proceedings of the 19th Annual International Conference of the IEEE* Bd. 4 IEEE, 1997, S. 1533–1535
- [159] SCHMIDT, Nico M. ; BLANKERTZ, Benjamin ; TREDER, Matthias S.: Online detection of error-related potentials boosts the performance of mental typewriters. In: *BMC Neuroscience* 13 (2012), Nr. 19, S. 1–13
- [160] SCHÖGL, Alois ; KRONEGG, Julien ; HUGGINS, Jane E. ; MASON, Steve G.: Evaluation Criteria for BCI Research. In: *Toward Brain-Computer Interfacing*. The MIT Press, 2007, Kapitel 19, S. 327–342
- [161] SCHWARZ, Gideon: Estimating the dimension of a model. In: *The Annals of Statistics* 6 (1978), Nr. 2, S. 461–464

- [162] SELLERS, Eric W. ; KRUSIENSKI, Dean J. ; MCFARLAND, Dennis J. ; VAUGHAN, Theresa M. ; WOLPAW, Jonathan R.: A P300 event-related potential brain-computer interface (BCI): The effects of matrix size and inter stimulus interval on performance. In: *Biological Psychology* 73 (2006), Nr. 3, S. 242–252
- [163] SINCLAIR, Christopher M. ; GASPER, Mason C. ; BLUM, Andrew S.: Basic Electronics in Clinical Neurophysiology. In: *The Clinical Neurophysiology Primer*. Humana Press, 2007, Kapitel 1, S. 3–18
- [164] STERMAN, M. B. ; EGNER, Tobias: Foundation and Practice of Neurofeedback for the Treatment of Epilepsy. In: *Applied Psychophysiology and Biofeedback* 31 (2006), Nr. 1, S. 21–35
- [165] STRAUBE, Sirko ; KRELL, Mario M.: How to evaluate an agent’s behavior to infrequent events?—Reliable performance estimation insensitive to class distribution. In: *Frontiers in Computational Neuroscience* 8 (2014), Nr. 43, S. 1–6
- [166] STREHL, Ute ; LEINS, Ulrike ; GOTH, Gabriella ; KLINGER, Christoph ; HINTERBERGER, Thilo ; BIRBAUMER, Niels: Self-regulation of slow cortical potentials: a new treatment for children with attention-deficit/hyperactivity disorder. In: *Pediatrics* 118 (2006), Nr. 5, S. e1530–e1540
- [167] TAKANO, Kouji ; KOMATSU, Tomoaki ; HATA, Naoki ; NAKAJIMA, Yasoichi ; KANSAKU, Kenji: Visual stimuli for the P300 brain-computer interface: A comparison of white/gray and green/blue flicker matrices. In: *Clinical Neurophysiology* 120 (2009), Nr. 8, S. 1562–1566
- [168] TEYMOURIAN, Amir ; LÜTH, Thorsten ; GRÄSER, Axel ; FELZER, Torsten ; NORDMANN, Rainer: Brain-Controlled Finite State Machine for Wheelchair Navigation. In: *Proceedings of the 10th International ACM SIGACCESS Conference on Computers and Accessibility*, ACM, 2008 (Assets ’08), S. 257–258

- [169] THOMSON, David J.: Spectrum Estimation and Harmonic Analysis. In: *Proceedings of the IEEE* 70 (1982), Nr. 9, S. 1055–1096
- [170] TONG, Jijun ; ZHU, Danhua: Multi-phase cycle coding for SSVEP based brain-computer interfaces. In: *BioMedical Engineering OnLine* 14 (2015), Nr. 5, S. 1–13
- [171] TOWNSEND, G. ; LAPALLO, B. K. ; BOULAY, C. B. ; KRUSIENSKI, D. J. ; FRYE, G. E. ; HAUSER, C. K. ; SCHWARTZ, N. E. ; VAUGHAN, T. M. ; WOLPAW, J. R. ; SELLERS, E. W.: A novel P300-based brain–computer interface stimulus presentation paradigm: Moving beyond rows and columns. In: *Clinical Neurophysiology* 121 (2010), Nr. 7, S. 1109–1120
- [172] TREJO, Leonard J. ; ROSIPAL, Roman ; MATTHEWS, Bryan: Brain–Computer Interfaces for 1-D and 2-D Cursor Control: Designs Using Volitional Control of the EEG Spectrum or Steady-State Visual Evoked Potentials. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 14 (2006), Nr. 2, S. 225–229
- [173] USAKLI, Ali B.: Improvement of EEG Signal Acquisition: An Electrical Aspect for State of the Art of Front End. In: *Computational Intelligence and Neuroscience* 2010 (2010), Nr. 12, S. 1–7
- [174] VAN SCHIE, Hein T. ; MARS, Rogier B. ; COLES, Michael G. H. ; BEKKERING, Harold: Modulation of activity in medial frontal and motor cortices during error observation. In: *Nature Neuroscience* 7 (2004), Nr. 5, S. 549–554
- [175] VIALATTE, François-Benoît ; MAURICE, Monique ; DAUWELS, Justin ; CICHOCKI, Andrzej: Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives. In: *Progress in Neurobiology* 90 (2010), Nr. 4, S. 418–438
- [176] VIDAL, Jacques J.: Toward direct brain-computer communication. In: *Annual Review of Biophysics and Bioengineering* 2 (1973), Nr. 1, S. 157–180

- [177] VIDAL, Jacques J.: Real-Time Detection of Brain Events in EEG. In: *Proceedings of the IEEE* 65 (1977), Nr. 5, S. 633–641
- [178] VOLOSYAK, Ivan: SSVEP-based Bremen-BCI interface—boosting information transfer rates. In: *Journal of Neural Engineering* 8 (2011), Nr. 3, S. 1–11
- [179] VOLOSYAK, Ivan ; CECOTTI, Hubert ; VALBUENA, Diana ; GRÄSER, Axel: Evaluation of the Bremen SSVEP based BCI in real world conditions. In: *2009 IEEE 11th International Conference on Rehabilitation Robotics* IEEE, 2009, S. 322–331
- [180] VOLOSYAK, Ivan ; VALBUENA, Diana ; LÜTH, Thorsten ; GRÄSER, Axel: Towards an SSVEP Based BCI With High ITR. (2010), S. 1–16
- [181] WANG, Niya ; QIAN, Tianyi ; ZHUO, Qing ; GAO, Xiaorong: Discrimination between Idle and Work States in BCI based on SSVEP. In: *2010 2nd International Conference on Advanced Computer Control (ICACC)* Bd. 4 IEEE, 2010, S. 355–358
- [182] WANG, Yijun ; GAO, Xiaorong ; HONG, Bo ; JIA, Chuan ; GAO, Shangkai: Brain-Computer Interfaces Based on Visual Evoked Potentials. In: *IEEE Engineering in Medicine and Biology Magazine* 27 (2008), Nr. 5, S. 64–71
- [183] WANG, Yijun ; WANG, Ruiping ; GAO, Xiaorong ; HONG, Bo ; GAO, Shangkai: A Practical VEP-Based Brain-Computer Interface. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 14 (2006), Nr. 2, S. 234–240
- [184] WEI, Bing ; WU, Xiaopei ; ZHANG, Daoxin: Design and implementation of an improved BCI System based on alpha rhythm. In: *2009 3rd International Conference on Bioinformatics and Biomedical Engineering (ICBBE)* IEEE, 2009, S. 1–4
- [185] WOLPAW, Jonathan R. ; BIRBAUMER, Niels ; HEETDERKS, William J. ; MCFARLAND, Dennis J. ; PECKHAM, P. H. ; SCHALK, Gerwin ; DONCHIN, Emanuel ;

- QUATRANO, Louis A. ; ROBINSON, Charles J. ; VAUGHAN, Theresa M.: Brain–Computer Interface Technology: A Review of the First International Meeting. In: *IEEE Transactions on Rehabilitation Engineering* 8 (2000), Nr. 2, S. 164–173
- [186] WOLPAW, Jonathan R. ; BIRBAUMER, Niels ; MCFARLAND, Dennis J. ; PFURTSCHELLER, Gert ; VAUGHAN, Theresa M.: Brain–computer interfaces for communication and control. In: *Clinical Neurophysiology* 113 (2002), Nr. 6, S. 767–791
- [187] WOLPAW, Jonathan R. ; LOEB, Gerald E. ; ALLISON, Brendan Z. ; DONCHIN, Emanuel ; DO NASCIMENTO, O. F. ; HEETDERKS, William J. ; NIJBOER, Femke ; SHAIN, William G. ; TURNER, James N.: BCI Meeting 2005–Workshop on Signals and Recording Methods. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 14 (2006), Nr. 2, S. 138–141
- [188] WOLPAW, Jonathan R. ; MCFARLAND, Dennis J.: Control of a two-dimensional movement signal by a noninvasive brain–computer interface in humans. In: *Proceedings of the National Academy of Sciences of the United States of America* 101 (2004), Nr. 51, S. 17849–17854
- [189] WOLPAW, Jonathan R. ; MCFARLAND, Dennis J. ; VAUGHAN, Theresa M.: Brain–Computer Interface Research at the Wadsworth Center. In: *IEEE Transactions on Rehabilitation Engineering* 8 (2000), Nr. 2, S. 222–226
- [190] WU, Zhenghua ; LAI, Yongxiu ; XIA, Yang ; WU, Dan ; YAO, Dezhong: Stimulator selection in SSVEP-based BCI. In: *Medical Engineering & Physics* 30 (2008), Nr. 8, S. 1079–1088
- [191] YAN, Mingmin ; TAMURA, Hiroki ; TANNO, Koichi: Gaze Estimation using Electrooculogram Signals and its Mathematical Modeling. In: *2013 IEEE 43rd International Symposium on Multiple-Valued Logic (ISMVL)* IEEE, 2013, S. 18–22



- [192] YOON, Hyunjin ; YANG, Kiyoungh ; SHAHABI, Cyrus: Feature Subset Selection and Feature Ranking for Multivariate Time Series. In: *IEEE Transactions on Knowledge and Data Engineering* 17 (2005), Nr. 9, S. 1186–1198
- [193] ZANDER, Thorsten O. ; KOTHE, Christian: Towards passive brain–computer interfaces: applying brain–computer interface technology to human–machine systems in general. In: *Journal of Neural Engineering* 8 (2011), Nr. 2, S. 1–5
- [194] ZHU, Danhua ; MOLINA, Gary G. ; MIHAJLOVIĆ, Vojkan ; AARTS, Ronald M.: Phase synchrony analysis for SSVEP-based BCIs. In: *2010 2nd International Conference on Computer Engineering and Technology (ICCET)* Bd. 2 IEEE, 2010, S. 329–333
- [195] ZIEHE, Andreas ; LASKOV, Pavel ; NOLTE, Guido ; MÜLLER, Klaus-Robert: A Fast Algorithm for Joint Diagonalization with Non-orthogonal Transformations and its Application to Blind Source Separation. In: *Journal of Machine Learning Research* 5 (2004), S. 777–800



## Anhang A.

### Testdaten der sBCI-Studie

Tabelle A.1.: Ergebnisse der Studie aus Abschnitt 3.3 für die Auswahl von Haushaltsgeräten mit dem ERD/ERS-BCI.

Proband	Zeit pro Kommando (s)			
	Min.	Max.	Mittelw.	SD
1	5,592	95,144	26,671	27,752
2	3,812	33,134	11,135	7,091
3	2,484	23,181	7,814	4,569
4	3,578	74,834	38,623	23,320
5	5,417	32,968	13,971	8,024
6	3,260	31,526	12,811	7,088
7	2,842	135,835	38,230	39,234
8	2,219	44,591	16,202	11,374
9	5,374	113,150	45,249	36,086
10	4,171	191,539	25,249	42,499
11	2,359	15,618	6,342	4,034
12	7,624	41,432	16,399	9,690
13	2,734	34,262	14,161	7,774
14	2,375	77,265	21,725	19,982
15	2,921	33,937	10,076	7,416
Gesamt	2,219	191,539	18,474	22,250

Tabelle A.2.: Ergebnisse der Studie aus Abschnitt 3.3 für die Steuerung von Haushaltsgeräten mit dem SSVEP-BCI.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	70,00	100,00	93,64	9,71	7,12	46,97	24,97	10,31
2	56,25	100,00	81,28	12,63	2,25	25,02	11,14	6,83
3	65,38	100,00	84,54	11,82	5,42	42,67	18,21	10,91
4	69,23	100,00	90,31	12,05	4,17	39,42	15,55	8,79
5	70,59	100,00	91,80	9,33	4,23	32,78	17,72	8,35
6	75,00	100,00	92,00	8,26	7,67	31,37	19,51	6,98
7	61,54	100,00	85,95	13,60	3,49	31,92	15,02	8,55
8	64,71	100,00	89,45	10,16	8,10	43,59	24,62	9,03
9	50,00	100,00	75,60	13,23	3,01	28,38	11,76	6,47
10	71,43	100,00	88,30	8,53	3,48	17,65	10,33	3,91
11	55,56	100,00	83,52	14,05	3,64	31,33	13,94	7,89
12	46,67	88,89	71,03	12,89	0,78	13,30	5,13	3,52
13	65,38	100,00	86,83	12,76	6,26	26,21	15,12	7,29
14	73,33	100,00	93,07	8,32	8,07	39,83	17,66	8,86
15	73,33	100,00	92,56	9,81	5,05	23,16	12,23	6,79
16	68,42	100,00	88,57	10,34	5,46	24,20	13,60	6,07
Gesamt	46,67	100,00	87,27	12,33	0,78	46,97	15,99	9,29

Tabelle A.3.: Ergebnisse der Studie aus Abschnitt 3.3.3 für das Training von Bewegungsvorstellungen.

Proband	Genauigkeit (%)											
	1. Sitzung				2. Sitzung				3. Sitzung			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	33,33	56,67	42,22	12,62	26,67	53,33	42,00	9,89	26,67	36,67	30,00	4,08
2	46,67	50,00	48,33	1,92	46,67	70,00	57,22	8,28	33,33	83,33	58,33	19,64
3	73,33	93,33	82,22	10,18	56,67	90,00	70,83	15,49	73,33	90,00	81,33	6,06
4	33,33	43,33	37,78	5,09	16,67	40,00	27,50	11,01	0,00	33,33	16,67	15,87
5	0,00	40,00	20,00	28,28	73,33	83,33	76,67	5,77	70,00	80,00	76,00	4,35
6	93,33	96,67	94,44	1,92	83,33	93,33	87,50	4,19	86,67	100,00	90,00	6,67
7	43,33	43,33	43,33	0,00	23,33	36,67	27,78	7,70	40,00	73,33	60,67	12,56
8	20,00	36,67	28,89	8,39	30,00	56,67	44,67	9,60	23,33	40,00	33,33	7,07
9	0,00	0,00	0,00	-	23,33	40,00	30,00	8,82	16,67	40,00	32,00	9,01
10	33,33	46,67	40,00	9,43	6,67	6,67	6,67	-	0,00	6,67	3,33	3,33
11	-	-	-	-	76,67	93,33	85,00	11,79	70,00	76,67	74,00	2,79
12	33,33	50,00	40,00	8,82	30,00	43,33	38,33	6,38	36,67	50,00	43,33	5,27
13	33,33	36,67	35,00	2,36	30,00	50,00	40,00	8,50	26,67	56,67	41,67	14,01
14	16,67	33,33	25,00	11,79	23,33	40,00	30,00	7,20	13,33	43,33	29,17	13,44
15	80,00	90,00	86,00	4,35	73,33	86,67	80,56	5,74	63,33	93,33	76,67	10,75
16	13,67	53,33	32,33	19,94	50,00	63,33	55,56	5,02	53,33	63,33	56,67	4,71



## Anhang B.

### Testdaten der schrittweisen Roboterarmsteuerung

Tabelle B.1.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den großen LEDs.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	83,33	100,00	97,84	4,70	20,28	39,91	32,74	5,69
2	100,00	100,00	100,00	0,00	50,44	57,55	55,33	1,76
3	84,62	100,00	98,78	3,90	23,52	51,23	44,11	6,35
4	100,00	100,00	100,00	0,00	37,89	52,10	45,88	4,08
5	100,00	100,00	100,00	0,00	52,66	56,05	54,41	1,08
6	100,00	100,00	100,00	0,00	39,03	56,10	47,21	5,04
7	92,31	100,00	99,62	1,72	29,33	53,61	45,64	5,57
8	100,00	100,00	100,00	0,00	44,32	56,29	49,70	3,17
Gesamt	83,33	100,00	99,53	2,33	20,28	57,55	46,88	7,94

Tabelle B.2.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem phasenbasierten SSVEP-BCI und den großen LEDs.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	76,92	100,00	90,58	7,50	9,69	30,10	18,88	5,53
2	100,00	100,00	100,00	0,00	51,56	57,62	55,36	1,36
3	90,91	100,00	97,38	4,12	21,82	45,05	37,62	6,94
4	71,43	100,00	94,27	7,87	14,52	47,55	35,77	10,75
5	85,71	100,00	98,13	4,05	31,05	55,83	49,91	6,99
6	75,00	100,00	92,44	8,01	9,97	33,35	23,01	6,24
7	80,00	100,00	94,79	7,28	20,20	49,62	36,78	10,50
8	100,00	100,00	100,00	0,00	45,51	54,95	50,97	2,51
Gesamt	71,43	100,00	95,95	6,54	9,69	57,62	38,54	14,13

Tabelle B.3.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem P300-BCI und den LEDs des sBCI-Helmes.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	92,86	100,00	99,64	1,60	18,04	29,75	25,93	3,63
2	90,91	100,00	99,55	2,03	17,50	28,95	24,35	3,19
3	100,00	100,00	100,00	0,00	18,43	25,90	23,55	2,37
4	75,00	100,00	94,32	7,89	6,83	23,16	14,48	5,02
5	80,00	100,00	98,33	5,24	9,77	25,88	22,30	4,28
6	91,67	100,00	99,17	2,56	18,77	25,96	24,66	2,31
7	91,67	100,00	98,02	3,60	9,97	17,26	15,26	2,72
8	78,57	100,00	97,10	5,74	11,76	25,85	22,78	4,38
9	84,62	100,00	97,38	4,91	14,68	25,79	23,19	4,02
10	92,31	100,00	99,26	2,28	17,76	25,91	24,53	2,34
Gesamt	75,00	100,00	98,29	4,46	6,83	29,75	22,39	4,99



Tabelle B.4.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	100,00	100,00	100,00	0,00	36,81	51,89	45,25	3,98
2	87,50	100,00	96,14	4,93	12,67	33,49	19,88	6,71
3	90,91	100,00	97,85	3,89	27,73	46,83	40,21	6,71
4	85,71	100,00	96,83	4,98	27,20	48,00	38,53	6,66
5	100,00	100,00	100,00	0,00	40,85	54,86	50,85	4,03
6	84,62	100,00	95,91	5,41	20,71	50,17	34,93	9,58
7	92,31	100,00	99,62	1,72	21,19	40,71	29,66	5,67
8	90,91	100,00	97,65	3,71	18,45	50,90	32,77	8,65
9	87,50	100,00	98,96	3,28	34,11	57,61	51,47	5,98
10	85,71	100,00	97,99	4,28	24,24	50,27	37,36	6,43
Gesamt	84,62	100,00	98,19	3,79	12,67	57,61	38,04	11,11

Tabelle B.5.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 2-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes.

Proband	Genauigkeit (%)				ITR (bits/min)			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	100,00	100,00	100,00	0,00	37,50	54,55	47,47	4,69
2	83,33	100,00	98,61	4,81	8,32	35,56	26,29	7,71
3	75,00	100,00	97,92	7,22	17,29	42,86	36,73	7,49
4	87,50	100,00	98,20	4,26	17,64	40,00	30,88	7,36
5	100,00	100,00	100,00	0,00	35,04	50,53	44,25	6,02
6	100,00	100,00	100,00	0,00	21,15	49,46	34,75	7,95
7	100,00	100,00	100,00	0,00	21,95	45,72	35,23	5,91
8	80,00	100,00	95,94	7,36	10,11	38,68	23,50	8,44
9	88,89	100,00	99,44	2,48	30,55	51,25	47,00	4,20
10	88,89	100,00	99,44	2,48	20,07	54,23	44,34	7,02
Gesamt	75,00	100,00	98,93	4,07	8,32	54,55	37,08	10,59

Tabelle B.6.: Ergebnisse der Studie aus Abschnitt 4.6 für die Steuerung des 1-Tupel und des 2-Tupel Zustandsautomaten mit dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes.

		Zeit (s)					
		Min.	1. Quartil	Median	3. Quartil	Max.	Mittelw.
Aufgabe 1	1-Tupel	22,533	25,730	30,976	36,813	45,750	33,256
	2-Tupel	11,000	12,895	16,351	21,972	31,000	17,706
Aufgabe 2	1-Tupel	19,375	22,688	27,570	36,787	47,338	31,633
	2-Tupel	11,000	12,531	15,502	21,015	33,602	17,734
Aufgabe 3	1-Tupel	20,831	24,653	28,177	34,402	47,293	31,025
	2-Tupel	11,699	12,772	14,837	17,031	19,831	17,989
Aufgabe 4	1-Tupel	26,553	31,750	38,787	46,564	66,040	42,611
	2-Tupel	19,505	21,377	25,272	33,178	50,775	30,129

Tabelle B.7.: Ergebnisse der Studie aus Abschnitt 4.7 für die schrittweise Roboterarmsteuerung mit dem 2-Tupel Zustandsautomaten, dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes.

Proband	Zeit (min)							
	1. Teilaufgabe				2. Teilaufgabe			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	5,79	7,72	6,43	1,11	5,49	7,06	6,10	0,85
2	7,95	9,03	8,49	0,76	9,07	10,55	9,81	1,05
3	6,89	10,06	8,38	1,59	7,02	8,31	7,87	0,73
4	9,65	19,12	14,39	6,70	13,57	15,36	14,46	1,27
5	9,42	10,00	9,71	0,41	10,94	12,72	11,83	1,27
6	7,00	10,01	8,51	2,13	8,48	9,55	9,01	0,76
7	7,06	7,34	7,20	0,19	8,52	8,55	8,54	0,02
8	6,88	8,57	7,73	1,19	11,13	12,42	11,77	0,92
9	4,56	5,42	4,99	0,61	8,07	8,35	8,21	0,20
10	8,29	10,99	9,64	1,91	12,58	20,63	16,60	5,69
Gesamt	4,56	19,12	8,44	2,93	5,49	20,63	10,11	3,47

## Anhang C.

### Testdaten der geschwindigkeitsbasierten Roboterarmsteuerung

Tabelle C.1.: Ergebnisse der Kalibrierung aus Abschnitt 5.2 für das Alphawellen-BCI und die beiden Klassifikatoren MDRM und FGMDRM.

Proband	MDRM				FGMDRM			
	ACC	TPR	TNR	AUC	ACC	TPR	TNR	AUC
1	0,9817	1,0000	0,9633	1,0000	1,0000	1,0000	1,0000	1,0000
2	0,9917	0,9900	0,9933	0,9996	1,0000	1,0000	1,0000	1,0000
3	0,9397	0,9000	0,9793	0,9810	0,9753	0,9673	0,9833	0,9970
4	0,9967	1,0000	0,9933	1,0000	1,0000	1,0000	1,0000	1,0000
5	0,9933	0,9867	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
6	0,9964	0,9929	1,0000	1,0000	0,9993	0,9987	1,0000	1,0000
7	0,8603	0,7727	0,9480	0,9272	0,9863	0,9813	0,9913	0,9963
8	0,9900	0,9800	1,0000	0,9992	0,9990	0,9980	1,0000	1,0000
9	0,9823	0,9713	0,9933	0,9983	0,9990	0,9980	1,0000	1,0000
10	0,9693	0,9680	0,9707	0,9946	0,9933	0,9867	1,0000	0,9997
11	0,9810	1,0000	0,9620	0,9998	0,9967	1,0000	0,9933	1,0000
12	0,9483	0,9167	0,9800	0,9939	0,9830	0,9727	0,9933	0,9982
13	0,9733	0,9467	1,0000	0,9999	0,9947	0,9893	1,0000	1,0000
14	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
15	0,9087	0,8667	0,9507	0,9480	0,9703	0,9560	0,9847	0,9899
16	0,9237	0,9400	0,9073	0,9858	0,9970	0,9967	0,9973	0,9999
17	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000

Tabelle C.2.: Ergebnisse der Kalibrierung aus Abschnitt 5.3 für das Augenartefakt-HMI und die beiden Klassifikatoren MDRM und FGMDRM.

Proband	MDRM				FGMDRM			
	ACC	TPR	TNR	AUC	ACC	TPR	TNR	AUC
1	1,0000	1,0000	1,0000	1,0000	0,9997	1,0000	0,9993	1,0000
2	0,9750	0,9540	0,9960	0,9993	0,9870	0,9740	1,0000	0,9999
3	0,9947	1,0000	0,9893	0,9999	0,9907	0,9880	0,9933	0,9995
4	0,9937	0,9900	0,9973	1,0000	0,9847	0,9700	0,9993	0,9999
5	0,9987	1,0000	0,9973	1,0000	0,9920	0,9840	1,0000	1,0000
6	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
7	0,9867	1,0000	0,9733	1,0000	1,0000	1,0000	1,0000	1,0000
8	0,9900	0,9800	1,0000	1,0000	0,9970	0,9940	1,0000	1,0000
9	0,9865	0,9796	0,9933	0,9990	0,9847	0,9735	0,9960	0,9992
10	0,9807	0,9673	0,9940	0,9993	0,9956	1,0000	0,9913	0,9995
11	0,9620	0,9400	0,9840	0,9976	0,9640	0,9460	0,9820	0,9968
12	0,9704	0,9408	1,0000	0,9999	0,9898	0,9796	1,0000	0,9992
13	0,9820	0,9760	0,9880	0,9991	0,9810	0,9700	0,9920	0,9986
14	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000

Tabelle C.3.: Ergebnisse der Studie aus Abschnitt 5.5 für die geschwindigkeitsbasierte Roboterarmsteuerung mit dem 2-Tupel Zustandsautomaten, dem Alphawellen-BCI, dem Augenartefakt-HMI, dem frequenzbasierten SSVEP-BCI und den LEDs des sBCI-Helmes.

Proband	Zeit (min)							
	1. Teilaufgabe				2. Teilaufgabe			
	Min.	Max.	Mittelw.	SD	Min.	Max.	Mittelw.	SD
1	3,48	4,45	3,97	0,42	3,76	4,25	4,06	0,21
2	4,39	4,90	4,64	0,36	5,51	7,23	6,37	1,21
3	5,32	5,64	5,48	0,23	5,24	5,51	5,38	0,19
4	5,66	7,01	6,34	0,96	6,75	7,66	7,20	0,64
5	4,99	6,64	5,75	0,83	4,71	5,86	5,43	0,63
6	8,78	14,20	11,49	3,83	6,56	8,82	7,69	1,60
7	4,09	4,38	4,24	0,21	4,18	4,94	4,56	0,54
8	3,70	6,04	4,46	1,07	4,67	5,53	5,13	0,40
9	3,98	4,98	4,48	0,71	6,16	7,04	6,60	0,62
10	7,75	8,07	7,91	0,23	10,40	12,40	11,40	1,41
Gesamt	3,48	14,20	5,61	2,30	3,76	12,40	6,06	2,05

## Anhang D.

### Testdaten der Fehlererkennung

Tabelle D.1.: Ergebnisse der Kalibrierung aus Abschnitt 6.1 für das ErrP-BCI und die beiden Klassifikatoren MDRM und FGMDRM.

Proband	MDRM				FGMDRM			
	BA	TPR	TNR	AUC	BA	TPR	TNR	AUC
1	0,8620	0,8304	0,8935	0,9386	0,9309	0,8957	0,9661	0,9710
2	0,9430	0,8940	0,9921	0,9854	0,9522	0,9140	0,9905	0,9809
3	0,8250	0,8107	0,8393	0,9008	0,8853	0,8357	0,9348	0,9444
4	0,8866	0,8190	0,9541	0,9476	0,8873	0,8241	0,9504	0,9604
5	0,7369	0,6370	0,8368	0,8305	0,7997	0,7019	0,8976	0,8904
6	0,7335	0,6078	0,8592	0,8491	0,8247	0,7294	0,9200	0,8704
7	0,7969	0,7193	0,8744	0,8469	0,8456	0,7702	0,9211	0,9081
8	0,7521	0,6696	0,8347	0,8599	0,8147	0,7261	0,9032	0,8812
9	0,7802	0,7054	0,8550	0,8853	0,8632	0,7661	0,9603	0,9580
10	0,8781	0,8037	0,9526	0,9507	0,8950	0,8204	0,9696	0,9557
11	0,8848	0,8426	0,9269	0,9346	0,8898	0,8426	0,9369	0,9303
12	0,8348	0,7680	0,9015	0,9305	0,8656	0,8020	0,9292	0,9414
13	0,7719	0,6740	0,8698	0,8757	0,8251	0,7280	0,9222	0,9159

Tabelle D.2.: Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem MDRM-Klassifikator und einer aktiven Steuerung.

Proband	Am Ziel vorbei			Am Ziel gestoppt			Beide Fälle kombiniert		
	BA	TPR	TNR	BA	TPR	TNR	BA	TPR	TNR
1	0,7873	0,5926	0,9820	0,9334	0,8984	0,9683	1,0000	1,0000	1,0000
2	0,8621	0,7407	0,9834	0,9268	0,8921	0,9616	0,9551	0,9444	0,9658
3	0,7136	0,4857	0,9415	0,8913	0,8387	0,9438	0,9467	0,9667	0,9268
4	0,8790	0,7815	0,9766	0,9314	0,8794	0,9835	0,9985	1,0000	0,9970
5	0,7995	0,6185	0,9805	0,8579	0,7762	0,9395	0,9323	0,9111	0,9534
6	0,8619	0,7370	0,9868	0,9450	0,9190	0,9709	0,9954	1,0000	0,9907
7	0,9407	0,8852	0,9962	0,9846	0,9778	0,9914	1,0000	1,0000	1,0000
8	0,8041	0,6185	0,9896	0,9773	0,9841	0,9705	0,9882	0,9889	0,9876
9	0,9309	0,8741	0,9878	0,9655	0,9413	0,9897	0,9771	0,9667	0,9876
10	0,7605	0,5444	0,9765	0,9418	0,9175	0,9662	0,9813	0,9778	0,9848

Tabelle D.3.: Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem FGMDRM-Klassifikator und einer aktiven Steuerung.

Proband	Am Ziel vorbei			Am Ziel gestoppt			Beide Fälle kombiniert		
	BA	TPR	TNR	BA	TPR	TNR	BA	TPR	TNR
1	0,7849	0,5852	0,9846	0,9383	0,9063	0,9703	0,9944	0,9889	1,0000
2	0,8986	0,8000	0,9971	0,9659	0,9444	0,9874	0,9651	0,9333	0,9969
3	0,7114	0,4357	0,9872	0,9151	0,8710	0,9593	0,9581	0,9222	0,9939
4	0,8121	0,6407	0,9835	0,9348	0,8968	0,9728	1,0000	1,0000	1,0000
5	0,8696	0,7407	0,9984	0,9633	0,9492	0,9774	0,9873	0,9778	0,9969
6	0,8251	0,6556	0,9946	0,9699	0,9667	0,9732	1,0000	1,0000	1,0000
7	0,9128	0,8296	0,9960	0,9809	0,9746	0,9873	1,0000	1,0000	1,0000
8	0,8306	0,6667	0,9945	0,9704	0,9667	0,9742	1,0000	1,0000	1,0000
9	0,9327	0,8704	0,9951	0,9678	0,9429	0,9928	0,9889	0,9778	1,0000
10	0,7801	0,5778	0,9824	0,9309	0,8905	0,9713	0,9944	0,9889	1,0000

Tabelle D.4.: Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem MDRM-Klassifikator und einer passiven Steuerung.

Proband	Am Ziel vorbei			Am Ziel gestoppt			Beide Fälle kombiniert		
	BA	TPR	TNR	BA	TPR	TNR	BA	TPR	TNR
1	0,8733	0,7741	0,9726	0,9333	0,8857	0,9809	0,9923	1,0000	0,9846
2	0,8294	0,6889	0,9699	0,9378	0,8921	0,9835	0,9577	0,9333	0,9821
3	0,6684	0,3778	0,9590	0,8551	0,7984	0,9117	0,8654	0,8333	0,8975
4	0,9525	0,9185	0,9865	0,8579	0,7159	1,0000	0,9111	0,8222	1,0000
5	0,7369	0,5111	0,9627	0,8400	0,7381	0,9418	0,8737	0,8222	0,9251
6	0,7708	0,5704	0,9712	0,9190	0,8778	0,9602	0,9678	0,9667	0,9689
7	0,9341	0,8852	0,9829	0,9098	0,8222	0,9974	0,9611	0,9222	1,0000
8	0,8027	0,6667	0,9387	0,8714	0,8032	0,9396	0,8701	0,8667	0,8735
9	0,9573	0,9296	0,9849	0,9452	0,9048	0,9856	0,9885	0,9889	0,9880
10	0,8817	0,7852	0,9781	0,9471	0,9079	0,9863	0,9773	0,9667	0,9879

Tabelle D.5.: Ergebnisse der Kalibrierung aus Abschnitt 6.2 für das ERP-BCI mit dem FGMDRM-Klassifikator und einer passiven Steuerung.

Proband	Am Ziel vorbei			Am Ziel gestoppt			Beide Fälle kombiniert		
	BA	TPR	TNR	BA	TPR	TNR	BA	TPR	TNR
1	0,8562	0,7222	0,9902	0,9592	0,9397	0,9786	1,0000	1,0000	1,0000
2	0,7968	0,6074	0,9862	0,9338	0,8841	0,9835	0,9385	0,8889	0,9881
3	0,6801	0,3778	0,9823	0,8354	0,7032	0,9676	0,8425	0,7222	0,9627
4	0,9574	0,9148	1,0000	0,9915	0,9857	0,9974	0,9889	0,9778	1,0000
5	0,8120	0,6296	0,9945	0,9221	0,8667	0,9776	0,9511	0,9111	0,9910
6	0,7743	0,5630	0,9857	0,9258	0,8794	0,9722	0,9596	0,9222	0,9969
7	0,9341	0,8741	0,9941	0,9610	0,9254	0,9966	0,9667	0,9333	1,0000
8	0,8088	0,6333	0,9843	0,9427	0,9111	0,9744	0,9591	0,9333	0,9849
9	0,9715	0,9444	0,9985	0,9934	0,9905	0,9964	1,0000	1,0000	1,0000
10	0,9066	0,8148	0,9985	0,9768	0,9651	0,9885	0,9833	0,9667	1,0000